

А.А. АМОСОВ  
Ю.А. ДУБИНСКИЙ  
Н.В. КОПЧЕНОВА

---

**ВЫЧИСЛИТЕЛЬНЫЕ  
МЕТОДЫ  
ДЛЯ ИНЖЕНЕРОВ**

---

А.А. АМОСОВ  
Ю.А. ДУБИНСКИЙ  
Н.В. КОПЧЕНОВА

---

# ВЫЧИСЛИТЕЛЬНЫЕ МЕТОДЫ ДЛЯ ИНЖЕНЕРОВ

---

Рекомендовано Государственным комитетом Российской Федерации  
по высшему образованию в качестве учебного пособия  
для студентов высших технических учебных заведений



Москва «Высшая школа» 1994

ББК 32.97

А 62

УДК 683.1

Федеральная целевая программа книгоиздания России

Р е ц е н з е н т ы: кафедра прикладной математики МГТУ им. Баумана (зав. кафедрой д-р техн. наук, проф. В.С.Зарубин); чл.-кор. РАН, д-р физ.-мат. наук, проф. Н.Н.Калиткин

**Амосов А.А., Дубинский Ю.А., Копченова Н.В.**

**А62**      **Вычислительные методы для инженеров: Учеб. пособие. —**  
**М.: Высш. шк., 1994. — 544 с.: ил.**  
**ISBN 5-06-000625-5**

В книге рассматриваются вычислительные методы, наиболее часто используемые в практике инженерных и научно-технических расчетов: методы решения задач линейной алгебры и нелинейных уравнений, проблема собственных значений, методы теории приближения функций, численное дифференцирование и интегрирование, поиск экстремумов функций, решение обыкновенных дифференциальных уравнений. Значительное внимание уделяется особенностям реализации вычислительных алгоритмов на ЭВМ и оценке достоверности полученных результатов. Имеется большое количество примеров и геометрических иллюстраций.

Для студентов и аспирантов технических вузов, а также для инженеров и научных работников, применяющих вычислительные методы.

А  $\frac{1602120000 - 002}{001(01) - 94}$  Без объявл.

**ББК 32.97**  
**6Ф7.3**

ISBN 5-06-000625-5

© А.А.Амосов, Ю.А.Дубинский, Н.В.Копченова, 1994

Цель расчетов — не числа, а понимание.

*Р.В.Хелминг*

Из нашего девиза "Цель расчетов — не числа, а понимание" следует, что человек, который должен этого понимания достигнуть, обязан знать, как происходит вычисление. Если он не понимает, что делается, то очень маловероятно, чтобы он извлек из вычислений что-нибудь ценное. Он видит голые цифры, но их истинное значение может оказаться скрытым в вычислениях.

*Р.В.Хелминг*

## ПРЕДИСЛОВИЕ

В настоящее время имеется значительное число учебников и монографий, посвященных методам вычислений (часть из них отражена в списке литературы к данному пособию). Однако, на наш взгляд, большинство этих книг ориентировано на студентов-математиков или на специалистов по вычислительной математике. В то же время практически отсутствует отечественная учебная литература, в которой доступным для студента технического вуза или инженера образом были бы изложены основы вычислительных методов, применяемых сегодня для решения инженерных задач. Особенно острой, по мнению авторов, является потребность в книге, которая содержала бы не только изложение начал численных методов, но и давала бы представление о реально используемых в вычислительной практике алгоритмах. Данное учебное пособие призвано в определенной степени восполнить этот пробел.

Настоящее пособие адресовано в первую очередь студентам и аспирантам высших технических учебных заведений, изучающим основы математического моделирования и численные методы. Авторы надеются на то, что эта книга будет полезна широкому кругу инженерных и научно-технических работников, которые намерены применять ЭВМ для решения прикладных задач.

При написании книги авторы использовали многолетний опыт преподавания курса вычислительных методов студентам и аспирантам различных специальностей Московского энергетического института, а также опыт работы на вычислительном центре МЭИ. Значительное влияние на выбор материала и характер изложения оказали также многочисленные дискуссии со слушателями существующего при МЭИ факультета повышения квалификации преподавателей вузов страны.



Авторы стремились, изложить материал по возможности наиболее простым и доступным образом. Объем знаний высшей математики, необходимый для понимания содержания книги, не выходит за рамки программы младших курсов вуза. Пособие содержит довольно много примеров, иллюстрирующих те или иные положения теории, а также демонстрирующих особенности вычислительных методов или работу конкретных алгоритмов. Тем не менее многие из рассматриваемых вопросов трудны для восприятия и требуют внимательного изучения. К сожалению, в учебной литературе они нередко опускаются. К таким центральным вопросам относятся, например, понятия корректности, устойчивости и обусловленности вычислительных задач и вычислительных алгоритмов, особенности поведения вычислительной погрешности. Важность их понимания для эффективного применения ЭВМ сегодня велика и не акцентировать на них внимание авторы посчитали невозможным.

Дадим краткое изложение основного содержания книги. Важную идейную нагрузку несут на себе первые три главы. Рассматриваемые в них вопросы закладывают фундамент, необходимый для правильного понимания рассматриваемых в остальных главах вычислительных методов.

В гл. 1 дается общее представление о методе математического моделирования, в том числе о процессе создания математических моделей, о последовательности этапов решения инженерной задачи с применением ЭВМ, о вычислительном эксперименте.

В гл. 2 наряду с введением в элементарную теорию погрешностей содержится изложение основных особенностей машинной арифметики. Понимание этих особенностей необходимо тем, кто заинтересован в эффективном применении ЭВМ для решения прикладных задач.

В гл. 3 обсуждаются важнейшие свойства вычислительных задач, методов и алгоритмов. Дается общее представление о корректности, устойчивости и обусловленности вычислительной задачи. Приводится описание основных классов вычислительных методов. Значительное внимание уделяется устойчивости вычислительных алгоритмов, их чувствительности к ошибкам. Дается представление о различных подходах к анализу ошибок, в том числе и об обратном анализе ошибок. Обсуждаются требования, предъявляемые к вычислительным алгоритмам.

Конкретные вычислительные задачи и методы их решения рассматриваются начиная с гл. 4. Здесь авторы стремились к тому, чтобы не только изложить простейшие подходы, но и дать представление об алгоритмах, которые реально используются для решения соответствующих задач.

В гл. 4 рассматриваются методы отыскания решений нелинейных уравнений. Значительное внимание уделено постановке задачи и ее свойствам, в частности — чувствительности корней нелинейных уравнений к погрешностям. Среди различных методов отыскания корней более подробно излагаются метод простой итерации, метод Ньютона и различные их модификации.

В гл. 5 рассмотрены прямые (точные) методы решения систем линейных алгебраических уравнений. Основное внимание уделяется методу Гаусса и его различным модификациям. Рассматривается использование  $LU$ -разложения матриц для решения систем линейных уравнений, метод квадратных корней, метод прогонки, методы вращений и отражений. Обсуждается алгоритм итерационного уточнения.

В гл. 6 рассматриваются итерационные методы решения систем линейных алгебраических уравнений: метод простой итерации, метод Зейделя, метод релаксации и другие методы.

В гл. 7 рассматривается задача отыскания решений систем нелинейных уравнений. Обсуждаются не только соответствующие итерационные методы, но и различные подходы к решению сложной задачи локализации.

В гл. 8 дается представление о проблеме собственных значений и о различных подходах к вычислению собственных значений и собственных векторов. Излагаются степенной метод и обратный степенной метод, обсуждается  $QR$ -алгоритм.

В гл. 9 излагаются наиболее известные численные методы решения задачи одномерной минимизации, в том числе метод деления отрезка пополам, метод Фибоначчи, метод золотого сечения и метод Ньютона.

В гл. 10 рассматриваются различные методы решения задачи безусловной минимизации. Наиболее полно изложены градиентный метод, метод Ньютона и метод сопряженных градиентов.

В гл. 11 рассмотрены наиболее важные и часто встречающиеся в приложениях методы приближения функций. Значительное внимание уделено интерполяции, причем рассматривается интерполяция не только алгебраическими многочленами, но и тригонометрическими многочленами, а также интерполяция сплайнами. Достаточно подробно обсуждается метод наименьших квадратов. Дается понятие о наилучшем равномерном приближении и дробно-рациональных аппроксимациях.

В эту главу включены также некоторые вопросы, имеющие непосредственное отношение к методам приближения функций. Это конечные и разделенные разности, многочлены Чебышева, быстрое дискретное преобразование Фурье.

В гл. 12 рассматриваются различные подходы к выводу формул численного дифференцирования, обсуждается чувствительность этих формул к ошибкам в вычислении значений функции.

В гл. 13 излагаются методы вычисления определенных интегралов. Выводятся квадратурные формулы интерполяционного типа и квадратурные формулы Гаусса. Дается представление о принципах построения адаптивных процедур численного интегрирования и, в частности, об используемых в них способах апостериорной оценки погрешности. Рассматриваются различные подходы к вычислению интегралов от функций, имеющих те или иные особенности. В

частности, затрагивается проблема интегрирования быстро осциллирующих функций.

Гл. 14 посвящена численным методам решения задачи Коши для обыкновенных дифференциальных уравнений. Подробно рассматриваются метод Эйлера и его различные модификации. Значительное внимание уделено рассмотрению классических методов Рунге—Кутты и Адамса. Обсуждаются различные свойства устойчивости численных методов решения задачи Коши, в том числе нуль-устойчивость, абсолютная устойчивость,  $A$ -устойчивость,  $A(\alpha)$ -устойчивость. Специально рассматриваются жесткие задачи и методы их решения.

В гл. 15 изучаются методы численного решения двухточечных краевых задач. Подробно излагается применение метода конечных разностей к решению краевых задач для обыкновенного дифференциального уравнения второго порядка. Дается представление о проекционных методах Ритца и Галеркина; обсуждается один из их современных вариантов — метод конечных элементов. Завершает главу рассмотрение метода пристрелки.

Можно предположить, что к изучению отдельных параграфов или даже глав этой книги читатель приступит, только столкнувшись с необходимостью решить на ЭВМ важную для него задачу. Вероятно, в этом случае польза от изучения соответствующего раздела будет наибольшей. Многие вопросы рассмотрены очень кратко или не рассмотрены вообще. Авторы надеются на то, что соответствующие пробелы можно восполнить, используя сделанные в тексте ссылки на известные учебники и монографии.

В ряде случаев авторы позволяют себе интерпретировать те или иные результаты, делать определенные выводы и даже давать рекомендации в надежде на то, что для новичка соответствующие рассуждения дадут полезный начальный ориентир. В целом же ко всяким рекомендациям в такой сложной и многообразной области, как применение вычислительных методов для решения прикладных задач на ЭВМ, следует относиться с осторожностью. Они не могут претендовать на бесспорность и их следует рассматривать скорее как отражение точки зрения авторов.

Иногда то или иное положение обосновывается ссылкой на вычислительную практику. Хотя критерий практики и играет при отборе методов вычислений существенную роль, все же оценки методов, основанные на результатах их применения для решения конкретных задач, нередко бывают весьма субъективны и противоречивы.

В заключение отметим, что никакие теоретические положения и советы не могут заменить собственного опыта вычислительной работы. Как надеются авторы, параллельно с изучением данной книги такой опыт может приобрести читатель переходя от решения задач учебного характера к серьезным практическим задачам.

*Авторы*

## *Глава 1*

### **МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ И РЕШЕНИЕ ИНЖЕНЕРНЫХ ЗАДАЧ С ПРИМЕНЕНИЕМ ЭВМ**

В этой главе дается общее представление о методе математического моделирования, в том числе о процессе создания математических моделей, о последовательности этапов решения инженерной задачи с применением ЭВМ, о вычислительном эксперименте.

Разделение решаемых с применением ЭВМ прикладных задач на инженерные, научные, экономические и т.п. является до известной степени условным. Тем не менее при написании данного пособия авторы ориентировались на читателя, интересующегося решением именно инженерных задач. Попытаемся охарактеризовать этот класс задач, выделив его некоторые характерные особенности.

1. Инженерные задачи имеют ярко выраженную практическую направленность. Целью их решения является создание новой конструкции, разработка нового технологического процесса, минимизация затрат на производство некоторого изделия и т.д. Поэтому для таких задач характерна необходимость доведения результатов до конкретных чисел, графиков, таблиц, на основании которых можно принимать решения.

2. Эти задачи характеризуются значительным объемом выполняемой вычислительной работы.

3. Для этих задач характерно использование достаточно сложных математических моделей и серьезного математического аппарата.

4. Как правило, инженерные задачи решают специалисты, имеющие техническое образование, но не являющиеся профессионалами в области разработки математических методов и программного обеспечения ЭВМ. Поэтому естественно желание этих специалистов использовать готовые вычислительные методы и стандартное математическое программное обеспечение.

Наконец, условимся считать, что в рассматриваемый класс задач входят задачи только умеренной сложности. Для их решения не требуются сверхбольшие скорости вычислений и сверхбольшие объемы

памяти для хранения данных. Таким образом, эти задачи могут быть решены с помощью ЭВМ, доступных массовому пользователю. Те же задачи, которые требуют для решения сверхмощной вычислительной техники и принципиально новых алгоритмов, будем относить к категории научных задач.

### **§ 1.1. Математическое моделирование и процесс создания математической модели**

*Математическое моделирование* представляет собой метод исследования объектов и процессов реального мира с помощью их приближенных описаний на языке математики — *математических моделей*. Этот метод чрезвычайно плодотворен и известен уже несколько тысячелетий. Насущные задачи земледелия и строительства еще в древние времена приводили к необходимости определения площадей и объемов, а следовательно, и к рассмотрению элементарных геометрических фигур, дающих пример простейших математических моделей. Возможности математического моделирования и его влияния на научно-технический прогресс неизмеримо возросли в последние десятилетия в связи с созданием и широким внедрением ЭВМ.

Процесс создания математической модели условно можно разбить на ряд основных этапов: 1) построение математической модели; 2) постановка, исследование и решение соответствующих вычислительных задач; 3) проверка качества модели на практике и модификация модели. Рассмотрим основное содержание этих этапов.

**1. Построение математической модели.** Предполагается, что с помощью наблюдений и экспериментов, практики (понимаемой в самом широком смысле) получена достаточно подробная информация об изучаемом явлении. Для рассматриваемого этапа характерно глубокое проникновение в полученные факты с целью выяснения главных закономерностей. Выявляются основные "характеристики" явления, которым сопоставляются некоторые величины. Как правило, эти величины принимают числовые значения, т.е. являются переменными, векторами, матрицами, функциями и т.д.

Установленным внутренним связям между "характеристиками" явления придается форма равенств, неравенств, уравнений и логических структур, связывающих величины, включенные в математическую модель. Таким образом, математическая модель становится записью на языке математики законов природы, управляющих протеканием исследуемого процесса или описывающих функционирование изучаемого

объекта. Она включает в себя набор некоторых величин и описание характера связи между ними.

Построение математических моделей — существенная и очень важная часть естественных и технических наук. Эта задача, требующая от исследователя глубокого знания предметной области, высокой математической культуры, опыта построения моделей, развитой интуиции и многого другого. Создание удачной новой модели — всегда крупное достижение соответствующей науки, а иногда и целый этап в ее развитии.

Подчеркнем, что математическая модель неизбежно представляет собой компромисс между бесконечной сложностью изучаемого явления и желаемой простотой его описания. Модель должна быть достаточно полной, для того чтобы оказаться полезной для изучения свойств исследуемого явления. В то же время она обязана быть достаточно простой, для того чтобы допускать возможность ее анализа существующими в математике средствами и ее реализации на ЭВМ. Из огромного числа характеристик явления и действующих на него факторов требуется выделить основные, определяющие, отбросив при этом второстепенные, несущественные.

Нередко в математическую модель закладываются некоторые гипотезы, еще не подтвержденные на практике. Такую математическую модель часто называют *гипотетической*.

Приведем пример простейшей математической модели.

**Пример 1.1.** Пусть исследуется движение тела, брошенного со скоростью  $v_0$  под углом  $\alpha$  к поверхности Земли.

Будем считать, что в рассматриваемом случае можно пренебречь сопротивлением воздуха, считать Землю плоской, а ускорение свободного падения  $g$  — постоянной. Введем систему координат, ее начало поместим в точку бросания, ось  $Ox$  направим горизонтально в направлении бросания, а ось  $Oy$  — вертикально вверх (рис. 1.1). Пусть  $u(t)$  и  $w(t)$  — горизонтальная и вертикальная составляющие скорости  $v(t)$  в момент времени  $t$  (в начальный момент  $t = 0$ ,  $v = v_0$ ).

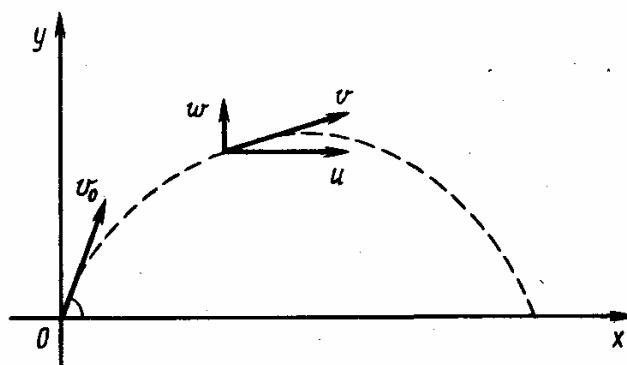


Рис. 1.1

Согласно законам механики, при сделанных предположениях движение тела в горизонтальном направлении является равномерным, а в вертикальном —

равноускоренным с ускорением, равным  $-g$ . Поэтому справедливы следующие равенства:

$$u = v_0 \cos \alpha, \quad x = (v_0 \cos \alpha)t, \quad (1.1)$$

$$w = v_0 \sin \alpha - gt, \quad y = (v_0 \sin \alpha)t - \frac{gt^2}{2}. \quad (1.2)$$

Формулы (1.1), (1.2) и дают простейшую математическую модель рассматриваемого явления, созданную в XVII в. Г.Галилеем<sup>1</sup>. Заметим, что при  $0 < \alpha < \pi/2$  траектория движения представляет собой параболу

$$y = -\frac{g}{2v_0^2 \cos^2 \alpha} x^2 + (\operatorname{tg} \alpha) x.$$

Математические модели часто разделяют на статические и динамические. *Статическая модель* описывает явление или ситуацию в предположении их завершенности, неизменности (т.е. в статике). *Динамическая модель* описывает, как протекает явление или изменяется ситуация от одного состояния к другому (т.е. в динамике). При использовании динамических моделей, как правило, задают начальное состояние системы, а затем исследуют изменение этого состояния во времени.

**2. Постановка, исследование и решение вычислительных задач.** Для того чтобы найти интересующие исследователя значения величин или выяснить характер их зависимости от других входящих в математическую модель величин, ставят, а затем решают математические задачи.

Выявим основные типы решаемых задач. Для этого все величины, включенные в математическую модель, условно разобьем на три группы: 1) *исходные (входные) данные*  $x$ ; 2) *параметры модели*  $a$ ; 3) *искомое решение (выходные данные)*  $y$ . В динамических моделях искомое решение часто является функцией времени  $y = y(t)$ ; переменная  $t$  в таких моделях, как правило, бывает выделенной и играет особую роль.

Наиболее часто решают так называемые *прямые задачи*, постановка которых выглядит следующим образом: по данному значению входного данного  $x$  при фиксированных значениях параметров  $a$  требуется найти решение  $y$ . Процесс решения прямой задачи можно рассматривать как математическое моделирование причинно-следственной связи, присущей явлению. Тогда входное данное  $x$  характеризует "причины" явления, которые задаются и варьируются в процессе исследования, а искомое решение  $y$  — "следствие".

---

<sup>1</sup> Галилео Галилей (1564 — 1642) — итальянский физик, механик, астроном, один из основателей точного естествознания.

Для того чтобы математическое описание было применимо не к единичному явлению, а к широкому кругу близких по природе явлений, в действительности строят не единичную математическую модель, а некоторое параметрическое семейство моделей. Будем считать, что выбор конкретной модели из этого семейства осуществляется фиксацией значений параметров модели  $a$ . Например, в роли таких параметров могут выступать некоторые из коэффициентов, входящих в уравнения. С помощью выбора параметров может производиться указание типа функциональной зависимости между некоторыми из величин. Наконец, если используемые математические модели разбиты на классы, то параметром может служить и класс используемой модели.

**Пример 1.2.** Для модели (1.1), (1.2) прямую задачу естественно формулировать как задачу вычисления величин  $u(t)$ ,  $w(t)$ ,  $x(t)$ ,  $y(t)$  по задаваемым входным данным  $u_0$ ,  $\alpha$ . Параметром модели здесь является величина ускорения свободного падения  $g$ . Ее значение зависит от того, производится ли бросание тела с поверхности Земли на уровне Мирового океана, в глубокой шахте или же на большой высоте. Заметим, что та же модель пригодна для описания движения тела, брошенного на любой другой планете, если значение параметра  $g$  для этой планеты известно.

Большую роль играет решение так называемых *обратных задач*, состоящих в определении входного данного  $x$  по данному значению  $y$  (параметры модели  $a$ , как и в прямой задаче, фиксированы). Решение обратной задачи — это в определенном смысле попытка выяснить, какие "причины"  $x$  привели к известному "следствию"  $y$ . Как правило, обратные задачи оказываются сложнее для решения, чем прямые.

**Пример 1.3.** Для модели (1.1), (1.2) обратную задачу можно сформулировать так: по заданным  $u(t)$ ,  $w(t)$ ,  $x(t)$ ,  $y(t)$  требуется найти значения  $u_0$ ,  $\alpha$ . Заметим, что для однозначного определения  $u_0$ ,  $\alpha$  достаточно задать в любой фиксированный момент  $t_0 \geq 0$  одну из пар величин ( $u(t_0)$ ,  $w(t_0)$ ) или ( $x(t_0)$ ,  $y(t_0)$ ).

Помимо двух рассмотренных типов задач следует упомянуть еще один тип — *задачи идентификации*. В широком смысле задача идентификации модели — это задача выбора среди множества всевозможных моделей той, которая наилучшим образом описывает изучаемое явление. В такой постановке эта задача выглядит как практически неразрешимая проблема. Чаще задачу идентификации понимают в узком смысле, как задачу выбора из заданного параметрического семейства моделей конкретной математической модели (с помощью выбора ее параметров  $a$ ), с тем чтобы оптимальным в смысле некоторого крите-



рия образом согласовать следствия из модели с результатами наблюдений.

**Пример 1.4.** Применительно к модели (1.1), (1.2) задача идентификации может состоять в определении величины ускорения свободного падения планеты  $g$  по результатам наблюдений за параметрами траектории.

Указанные три типа задач (прямые, обратные и задачи идентификации) будем называть *вычислительными задачами*. Для удобства изложения в дальнейшем независимо от типа решаемой задачи будем называть набор подлежащих определению величин *искомым решением* и обозначать через  $y$ , а набор величин — *входными данными* и обозначать через  $x$ .

**Пример 1.5.** При описании многих явлений используют модель полиномиальной зависимости между величинами  $x$  и  $y$ :

$$y = P_n(x) \equiv a_0 + a_1x + \dots + a_nx^n. \quad (1.3)$$

Здесь  $a_0, a_1, \dots, a_n$  — коэффициенты многочлена, являющиеся параметрами модели (в число параметров модели можно включить и степень многочлена). При фиксированных значениях параметров прямая задача состоит в вычислении значения многочлена  $y = P_n(x)$  по заданному  $x$ . В таком случае целью решения обратной задачи является определение по заданному значению  $y$  соответствующего ему значения  $x$ . Нетрудно видеть, что это есть задача отыскания корней многочлена, отличающегося от  $P_n(x)$  заменой коэффициента  $a_0$  на  $\tilde{a}_0 = a_0 - y$ . Если же из практики известна некоторая информация о зависимости  $y$  от  $x$ , то определение параметров  $a_0, a_1, \dots, a_n$ , при которых модель (1.3) наилучшим в некотором смысле образом описывает эту зависимость, представляет собой задачу идентификации. Например, если задана таблица значений  $x_i, y_i$ , то такую задачу в зависимости от ситуации можно решать, используя известные методы интерполяции и наименьших квадратов (см. гл. 11).

**Пример 1.6.** Нередко входящие в модель функции  $x(t)$  и  $y(t)$  бывают связаны равенством

$$y(t) = \int_0^t x(\tau) d\tau + C.$$

Например, так связаны между собой скорость  $x(t)$  и путь  $y(t)$  при прямолинейном движении. Тогда при фиксированном значении постоянной  $C$  прямая

задача (задача интегрирования) состоит в вычислении первообразной  $y(t)$  по заданной функции  $x(t)$ . Обратная задача (задача дифференцирования) заключается в вычислении  $x(t) = y'(t)$  по заданной функции  $y(t)$ .

Как правило, решение вычислительной задачи не удается выразить через входные данные в виде конечной формулы. Однако это совсем не означает, что решение такой задачи не может быть найдено. Существуют специальные методы, которые называют *численными* (или *вычислительными*). Они позволяют свести получение численного значения решения к последовательности арифметических операций над численными значениями входных данных. Эти методы были известны давно: в качестве примера, уже ставшего классическим, можно привести открытие Леверье<sup>1</sup> в 1846 г. новой планеты Нептун. Однако для решения задач численные методы применялись довольно редко, так как их использование предполагает выполнение гигантского объема вычислений<sup>2</sup>. Поэтому в большинстве случаев до появления ЭВМ приходилось избегать использования сложных математических моделей и исследовать явления в простейших ситуациях, когда возможно найти аналитическое решение. Несовершенство вычислительного аппарата становилось фактором, сдерживающим широкое использование математических моделей в науке и технике.

Появление ЭВМ кардинально изменило ситуацию. Класс математических моделей, допускающих подробное исследование, резко расширился. Решение многих, еще недавно недоступных, вычислительных задач стало обыденной реальностью.

**3. Проверка качества модели на практике и модификация модели.** На этом этапе выясняют пригодность математической модели для описания исследуемого явления. Теоретические выводы и конкретные результаты, вытекающие из гипотетической математической модели, сопоставляют с экспериментальными данными. Если они противоречат друг другу, то выбранная модель непригодна и ее следует пересмотреть, вернувшись к первому этапу. Если же результаты совпадают с допустимой для описания данного явления точностью, то модель

---

<sup>1</sup> Урбен Жан Жозеф Леверье (1811 — 1877) — французский астроном. На основании законов небесной механики, используя данные об аномалиях в движении планеты Уран, Леверье рассчитал траекторию движения гипотетической неизвестной планеты. В том же году немецкий астроном Галле обнаружил Нептун в указанном Леверье месте.

<sup>2</sup> Расчет траектории планеты Нептун потребовал от Леверье нескольких месяцев кропотливой вычислительной работы.

можно признать пригодной. Конечно, необходимо дополнительное исследование с целью установления степени достоверности модели и границ ее применимости.

На определенном этапе развития науки и техники постепенное накопление знаний приводит к моменту, когда результаты, получаемые с помощью математической модели, вступают в противоречие с данными практики или перестают удовлетворять ее требованиям в смысле точности. Тогда возникает необходимость модификации модели или же создания принципиально новой, более сложной модели. Таким образом, цикл создания математической модели повторяется многократно.

**Пример 1.7.** Рассмотрим задачу внешней баллистики, т.е. задачу о движении артиллерийского снаряда. Простейшая модель (1.1), (1.2) дает параболическую траекторию движения снаряда, что, как было замечено еще в XVII в., противоречит данным практики. Существенным неучтенным фактором здесь является сопротивление воздуха.

Приведенная ниже модификация модели Галилея принадлежит И.Ньюто-ну<sup>1</sup>. Известно, что величина  $F$  силы лобового сопротивления воздуха пропорциональна квадрату скорости, т.е.  $F = -\beta v^2$ . При этом  $\beta = 0.5CS\rho$ , где  $\rho$  —

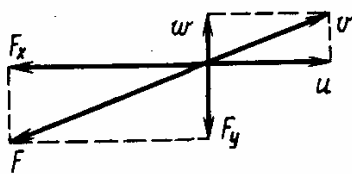


Рис. 1.2

плотность воздуха,  $S$  — площадь поперечного сечения,  $C$  — коэффициент лобового сопротивления (для многих задач баллистики  $C \approx 0.15$ ).

Обозначим через  $F_x$  и  $F_y$  горизонтальную и вертикальную проекции вектора лобового сопротивления. Заметим, что  $F_x/F = u/v$ ,  $F_y/F = w/v$ ,  $v = \sqrt{u^2 + w^2}$  (рис. 1.2). Следовательно  $F_x = -\beta u \sqrt{u^2 + w^2}$ ,  $F_y = -\beta w \sqrt{u^2 + w^2}$ .

Пусть  $m$  — масса снаряда. Тогда в силу второго закона Ньютона справедливы уравнения

$$m \frac{du}{dt} = -\beta u \sqrt{u^2 + w^2}, \quad \frac{dx}{dt} = u, \quad (1.4)$$

$$m \frac{dw}{dt} = -g - \beta w \sqrt{u^2 + w^2}, \quad \frac{dy}{dt} = w, \quad (1.5)$$

<sup>1</sup> Исаак Ньютон (1643 — 1727) — английский физик, механик, астроном и математик, заложивший основы современного естествознания.

которые необходимо дополнить начальными условиями

$$u(0) = v_0 \cos \alpha, \quad w(0) = v_0 \sin \alpha, \quad x(0) = 0, \quad y(0) = 0. \quad (1.6)$$

Полученная модель является более сложной, чем рассмотренная ранее модель (1.1), (1.2), однако она содержит ее как частный случай. Действительно, в случае  $\beta \neq 0$  (сопротивление воздуха отсутствует) уравнения (1.4) — (1.6) и (1.1), (1.2) эквивалентны.

Естественно, что модель (1.4) — (1.6) непригодна для решения задач современной баллистики и реально используемые модели значительно сложнее.

Заметим, что работа по созданию математической модели, как правило, проводится объединенными усилиями специалистов, хорошо знающих предметную область, и математиков, владеющих соответствующими разделами прикладной математики и способных оценить возможность решения возникающих вычислительных задач.

## **§ 1.2. Основные этапы решения инженерной задачи с применением ЭВМ**

Решение серьезной инженерной задачи с использованием ЭВМ — довольно длительный и сложный процесс. С определенной степенью условности его можно разбить на ряд последовательных этапов. Выделим следующие этапы: 1) постановка проблемы; 2) выбор или построение математической модели; 3) постановка вычислительной задачи; 4) предварительный (предмашинный) анализ свойств вычислительной задачи; 5) выбор или построение численного метода; 6) алгоритмизация и программирование; 7) отладка программы; 8) счет по программе; 9) обработка и интерпретация результатов; 10) использование результатов и коррекция математической модели.

**1. Постановка проблемы.** Первоначально прикладная задача бывает сформулирована в самом общем виде: исследовать некоторое явление, спроектировать устройство, обладающее заданными свойствами, дать прогноз поведения некоторого объекта в определенных условиях и т.д. На данной стадии происходит конкретизация постановки задачи, и первостепенное внимание при этом уделяется выяснению цели исследования. От исследователя требуется глубокое понимание существа задачи и умение сформулировать ее так, чтобы найденное решение было полезным и в то же время могло быть получено с помощью существующих методов и в реальные сроки. Неудачная постановка проблемы может привести к тому, что длительный и дорогостоящий процесс

решения задачи завершится получением бесполезных или тривиальных результатов (в этом случае возможно и отсутствие каких-либо результатов).

Этот очень важный и ответственный этап завершается конкретной формулировкой проблемы на языке, принятом в данной предметной области. Знание возможностей, которые дает применение ЭВМ, может оказать существенное влияние на окончательную формулировку проблемы.

**2. Выбор или построение математической модели.** Для последующего анализа исследуемого явления или объекта необходимо дать его формализованное описание на языке математики, т.е. построить математическую модель (см. § 1.1). Часто имеется возможность выбора модели среди известных и принятых для описания соответствующих процессов, но нередко требуется и существенная модификация известной модели, а иногда возникает необходимость в построении принципиально новой модели.

Рассматриваемый этап — едва ли не самый важный и трудный. Часто удачный выбор математической модели является решающим шагом к достижению цели. Одна из существенных трудностей такого выбора состоит в объективном противоречии между желанием сделать описание явления как можно более полным (что приводит к усложнению модели) и необходимостью иметь достаточно простую модель (чтобы была возможность реализовать ее на ЭВМ). Важно, чтобы сложность математической модели соответствовала сложности поставленной проблемы. Если поставленных целей можно достичь, используя более простую математическую модель, то ей и следует отдать предпочтение. Как правило, полезно иметь несколько упрощенных вариантов принимаемой модели. Заметим, что грамотное упрощение модели — непростая задача, однако анализ упрощенных моделей весьма полезен в течение всего процесса решения задачи. Такие упрощенные модели часто позволяют ответить на многие принципиальные вопросы и понять основные закономерности поведения более сложной модели.

**3. Постановка вычислительной задачи.** На основе принятой математической модели формулируют вычислительную задачу (или ряд таких задач). Анализируя результаты ее решения, исследователь предполагает получить ответы на интересующие его вопросы.

**4. Предварительный анализ свойств вычислительной задачи.** На этом этапе проводят предварительное (предмашинное) исследование свойств вычислительной задачи. Большое внимание уделяют анализу корректности ее постановки, т.е. выяснению вопросов существования и единственности решения, а также исследованию устойчивости решения

задачи к погрешностям входных данных (эти вопросы более подробно рассматриваются в гл. 3). Такое исследование, как правило, относится к компетенции профессиональных математиков. Тем не менее инженеру полезно быть в курсе современного состояния названных проблем, уметь самостоятельно проводить простейшие исследования.

К сожалению, для многих имеющих практическую ценность задач их строгое исследование в полной постановке провести не удастся и к решению приступают без детального анализа математических свойств этих задач. Это нежелательная, но вынужденная мера, так как в прикладных исследованиях существенное значение имеют конкретные (часто — весьма сжатые) сроки получения результата. На этом этапе полезным оказывается изучение упрощенных постановок задачи. Иногда для них удается провести исследование, позволяющее понять основные особенности исходной вычислительной задачи. Особую ценность имеют различные аналитические решения; они оказываются полезными не только для анализа явления, но и как основа для тестовых испытаний на этапе отладки программы.

**5. Выбор или построение численного метода.** Для решения вычислительной задачи на ЭВМ требуется использование численных методов.

Часто решение инженерной задачи сводится к последовательному решению стандартных вычислительных задач, для которых разработаны эффективные численные методы. В этой ситуации происходит либо выбор среди известных методов, либо их адаптация к особенностям решаемой задачи. Однако если возникающая вычислительная задача является новой, то не исключено, что для ее решения не существует готовых методов. Построение численного метода для такой задачи может оказаться очень трудной проблемой и потребовать привлечения специалиста по вычислительной математике. Умение различать отмеченные две ситуации необходимо, и наличие его уже говорит об определенной квалификации в области вычислительных методов.

Для решения одной и той же вычислительной задачи обычно может быть использовано несколько методов. Необходимо знать особенности этих методов, критерии, по которым оценивается их качество, чтобы выбрать метод, позволяющий решить проблему наиболее эффективным образом. Здесь выбор далеко не однозначен. Он существенно зависит от требований, предъявляемых к решению, от имеющихся в наличии ресурсов, от доступной для использования вычислительной техники и т.д.

Возникающим на этом этапе вопросам и посвящена большая часть данной книги.

**6. Алгоритмизация и программирование.** Как правило, выбранный

на предыдущем этапе численный метод содержит только принципиальную схему решения задачи, не включающую многие детали, без которых невозможна реализация метода на ЭВМ. Необходима подробная детализация всех этапов вычислений, для того чтобы получить реализуемый на ЭВМ алгоритм. Составление программы сводится к переводу этого алгоритма на выбранный язык программирования. Заметим, что в настоящее время для вычислительных задач наиболее широко используется алгоритмический язык ФОРТРАН.

В книге значительное место уделяется алгоритмам (в гл. 3 обсуждаются их общие свойства и критерии оценки качества) и практически не рассматриваются вопросы собственно программирования. Конечно, алгоритмизация и программирование очень тесно связаны. Более того, практика показывает, что небольшие, на первый взгляд, различия в программах могут привести к значительным различиям в их эффективности. Тем не менее вопрос разработки качественного программного продукта мы не затрагиваем (этому предмету посвящено большое число пособий). Подчеркнем лишь, что большинство пользователей справедливо предпочитает строить свои программы из готовых модулей и использовать стандартные программы, реализующие те или иные алгоритмы. Разумеется, отсутствие в библиотеке стандартных программ той или иной программы не должно быть непреодолимым препятствием.

**7. Отладка программы.** На этом этапе с помощью ЭВМ выявляют и исправляют ошибки в программе.

Как правило, начинающий пользователь ЭВМ убежден, что ошибок в составленной им программе нет или же они могут быть легко обнаружены и исправлены. Однако совершенно неожиданно для него отладка программы и доведение ее до рабочего состояния нередко оказывается длительным и весьма трудоемким процессом. Приобретая определенный опыт в составлении и отладке сравнительно сложных программ, пользователь убеждается в справедливости популярного афоризма: "В любой программе есть по крайней мере одна ошибка".

Таким образом, наличие в программах ошибок — вполне нормальное и закономерное явление. Поэтому подготовку к отладке следует начинать уже на этапе алгоритмизации и программирования. Заметим, что эффективность отладки самым существенным образом зависит от общей методики разработки программ.

После устранения ошибок программирования необходимо провести тщательное тестирование программы — проверку правильности ее работы на специально отобранных тестовых задачах, имеющих известные решения.

Основные вопросы методики отладки программ можно найти, например, в [10].

**8. Счет по программе.** На этом этапе происходит решение задачи на ЭВМ по составленной программе в автоматическом режиме. Этот процесс, в ходе которого входные данные с помощью ЭВМ преобразуются в результат, называют *вычислительным процессом*. Как правило, счет повторяется многократно с различными входными данными для получения достаточно полной картины зависимости от них решения задачи.

Первые полученные результаты тщательно анализируются, для того чтобы убедиться в правильности работы программы и пригодности выбранного метода решения. Счет по программе продолжается несколько секунд, минут или часов. Именно быстротечность этого этапа порождает распространенную иллюзию о возможности решать важные прикладные задачи на ЭВМ в очень короткое время. В действительности же, конечно, необходимо принимать во внимание весь цикл от постановки проблемы до использования результатов. Для серьезных задач часто полезные результаты получаются только в результате многолетней работы.

**9. Обработка и интерпретация результатов.** Полученные в результате расчетов на ЭВМ выходные данные, как правило, представляют собой большие массивы чисел. Начинаящий пользователь часто пытается вывести эти массивы на печать с тем, чтобы "потом провести их анализ". Обычно первый же опыт анализа распечатки, содержащий сотни тысяч чисел, приводит к пониманию того, что эта работа непосильна для человека и следует постараться возложить ее на ЭВМ.

Зачастую первоочередной интерес представляет лишь небольшая часть полученной информации (например, значения одной из функций в выделенных точках) или даже некоторая грубая интегральная характеристика (максимальное или минимальное значение, оценка энергии системы и т.д.).

Для того чтобы исследователь мог воспользоваться результатами расчетов, их необходимо представить в виде компактных таблиц, графиков или в иной удобной для восприятия форме. При этом следует максимально использовать возможности ЭВМ для подготовки такой информации и ее представления с помощью печатающих и графических выходных устройств.

Для правильной интерпретации результатов расчетов и оценки их достоверности от исследователя требуется глубокое знание существа решаемой инженерной задачи, ясное представление об используемой математической модели и понимание (хотя бы в общих чертах) особенностей применяемого вычислительного метода.



Вопросы обработки и интерпретации результатов вычислений будут затронуты при рассмотрении конкретных вычислительных методов и алгоритмов.

**10. Использование результатов и коррекция математической модели.** Завершающий этап состоит в использовании результатов расчетов в практической деятельности, иначе говоря, во внедрении результатов. Не стоит огорчаться, если большинство полученных сначала результатов окажется бесполезным. Действительно полезные для практики результаты являются плодом серьезной целенаправленной работы, в процессе которой цикл решения задачи повторяется неоднократно.

Очень часто анализ результатов, проведенный на этапе их обработки и интерпретации, указывает на несовершенство используемой математической модели и необходимость ее коррекции. В таком случае математическую модель модифицируют (при этом она, как правило, усложняется) и начинают новый цикл решения задачи.

### **§ 1.3. Вычислительный эксперимент**

Создание математических моделей и решение инженерных задач с применением ЭВМ требует выполнения большого объема работ (см. § 1.1, 1.2). Нетрудно заметить аналогию с соответствующими работами, проводимыми при организации натурных экспериментов: составление программы экспериментов, создание экспериментальной установки, выполнение контрольных экспериментов, проведение серийных опытов, обработка экспериментальных данных и их интерпретация и т.д. Однако вычислительный эксперимент проводится не над реальным объектом, а над его математической моделью, и роль экспериментальной установки играет оснащенная специально разработанной программой ЭВМ. В связи с этим естественно рассматривать проведение больших комплексных расчетов при решении инженерных и научно-технических задач как *вычислительный эксперимент*, а описанную в предыдущем параграфе последовательность этапов решения как один его цикл.

Широкое применение ЭВМ в математическом моделировании, разработанная теория и значительные практические результаты позволяют говорить о вычислительном эксперименте как о новой технологии и методологии научных и прикладных исследований. Серьезное внедрение вычислительного эксперимента в инженерную деятельность лишь начинается, но там где оно происходит реально (в авиационной и космической промышленности) его плоды весьма весомы.

Отметим некоторые достоинства вычислительного эксперимента по сравнению с натурным. Вычислительный эксперимент, как правило,

20

дешевле физического. В этот эксперимент можно легко и безопасно вмешиваться. Его можно повторить еще раз (если в этом есть необходимость) и прервать в любой момент. В ходе этого эксперимента можно смоделировать условия, которые нельзя создать в лаборатории.

Заметим, что в ряде случаев проведение натурального эксперимента затруднено (а иногда и невозможно), так как изучаются быстропротекающие процессы, исследуются труднодоступные или вообще пока недоступные объекты. Часто проведение полномасштабного натурального эксперимента сопряжено с губительными или непредсказуемыми последствиями (ядерная война, поворот сибирских рек) или с опасностью для жизни или здоровья людей. Нередко требуется исследование и прогнозирование результатов катастрофических явлений (авария ядерного реактора АЭС, глобальное потепление климата, землетрясение). В этих случаях вычислительный эксперимент может стать основным средством исследования. Заметим, что с его помощью оказывается возможным прогнозировать свойства новых, еще не созданных конструкций и материалов на стадии их проектирования.

Существенным недостатком вычислительного эксперимента является то, что применимость его результатов ограничена рамками принятой математической модели.

Конечно, вычислительный эксперимент никогда не сможет полностью заменить натуральный, и будущее за их разумным сочетанием. Действительно, построение математической модели основано на результатах наблюдений, опыта, а достоверность ее выводов проверяется с помощью критерия практики.

Для инженерных задач характерно наличие значительного числа параметров (конструктивных, технологических и др.). Создание нового изделия или технологического процесса предполагает выбор среди большого числа альтернативных вариантов, а также оптимизацию по ряду параметров. Поэтому в ходе вычислительного эксперимента расчеты проводятся многократно с разными значениями входных параметров. Для получения нужных результатов с требуемой точностью и в приемлемые сроки необходимо, чтобы на расчет каждого варианта тратилось минимальное время. Именно поэтому при создании программного обеспечения так важно использовать эффективные численные методы.

Разработка программного обеспечения вычислительного эксперимента в конкретной области инженерной деятельности приводит к созданию крупного программного комплекса. Он состоит из связанных между собой прикладных программ и системных средств, включающих средства, предоставляемые пользователю для управления ходом вычислительного эксперимента, обработки и представления его результа-

тов. Такой комплекс программ иногда называют *проблемно-ориентированным пакетом прикладных программ*.

#### **§ 1.4. Дополнительные замечания**

1. Математическое моделирование является основой современной методологии решения инженерных задач, и его роль объективно возрастает в связи с необходимостью решения все более сложных прикладных проблем.

2. Эффективность применения ЭВМ в той или иной области науки и техники тем выше, чем совершеннее ее математические модели. В то же время использование ЭВМ для исследования каких-либо процессов часто служит серьезным стимулом для создания новых математических моделей и детального изучения этих процессов другими методами.

3. Само по себе применение ЭВМ не позволяет решить инженерную задачу, а лишь дает в руки исследователя мощный инструмент познания. Использование ЭВМ не только не освобождает от необходимости глубоко осмыслить решаемую проблему, но и заставляет уделять постановке задачи гораздо больше внимания.

4. Вычислительный эксперимент не противоречит натурному эксперименту и классическому математическому анализу инженерной задачи, а, напротив, находится с ними в органическом единстве.

5. Для успешного применения метода математического моделирования с использованием ЭВМ необходимо гармоническое владение всеми его составляющими. В настоящем пособии основное внимание уделено вычислительным методам и алгоритмам, анализу свойств вычислительных задач, интерпретации получаемых результатов.

6. Дополнительную информацию о методологии современного математического моделирования и концепции вычислительного эксперимента можно получить из следующих источников: [65], [78], [81], [47], [58].

7. Популярное изложение принципов организации и функционирования проблемно-ориентированных пакетов прикладных программ содержится, например в [45].

## Глава 2

### ВВЕДЕНИЕ В ЭЛЕМЕНТАРНУЮ ТЕОРИЮ ПОГРЕШНОСТЕЙ

#### § 2.1. Источники и классификация погрешностей результата численного решения задачи

Для правильного понимания подходов и критериев, используемых при решении прикладной задачи с применением ЭВМ, очень важно с самого начала признать, что получить точное значение решения практически невозможно и не в этом цель вычислений. Получаемое на ЭВМ решение  $y^*$  почти всегда (за исключением некоторых весьма специальных случаев) содержит погрешность, т.е. является приближенным. Невозможность получения точного решения следует уже из ограниченной разрядности вычислительной машины.

Наличие погрешности решения обусловлено рядом весьма глубоких причин. Перечислим их.

1<sup>0</sup>. Математическая модель является лишь приближенным описанием реального процесса. Характеристики процесса, вычисленные в рамках принятой модели, заведомо отличаются от истинных характеристик, причем их погрешность зависит от степени адекватности модели реальному процессу.

2<sup>0</sup>. Исходные данные, как правило, содержат погрешности, поскольку они либо получаются в результате экспериментов (измерений), либо являются результатом решения некоторых вспомогательных задач.

3<sup>0</sup>. Применяемые для решения задачи методы в большинстве случаев являются приближенными. Найти решение возникающей на практике задачи в виде конечной формулы возможно только в отдельных, очень упрощенных ситуациях.

4<sup>0</sup>. При вводе исходных данных в ЭВМ, выполнении арифметических операций и выводе результатов на печать производятся округления.

Пусть  $y$  — точное значение величины, вычисление которой является

целью поставленной задачи. Соответствующая первым двум из указанных причин погрешность  $\delta_{\text{н}y}$  называется *неустранимой погрешностью*. Такое название вызвано тем, что принятие математической модели и задание исходных данных вносит в решение ошибку, которая не может быть устранена далее. Единственный способ уменьшить эту погрешность — перейти к более точной математической модели и задать более точные исходные данные.

Погрешность  $\delta_{\text{м}y}$ , источником которой является метод решения задачи, называется *погрешностью метода*, а погрешность  $\delta_{\text{в}y}$ , возникающая из-за округлений при вводе, выводе и вычислениях, — *вычислительной погрешностью*. Таким образом, полная погрешность результата решения задачи на ЭВМ  $\delta y = y - y^*$  складывается из трех составляющих: неустранимой погрешности, погрешности метода и вычислительной погрешности, т.е.  $\delta y = \delta_{\text{н}y} + \delta_{\text{м}y} + \delta_{\text{в}y}$ .

Будем далее исходить из предположения, что математическая модель фиксирована и входные данные задаются извне, так что повлиять на значение величины  $\delta_{\text{н}y}$  в процессе решения задачи действительно нельзя. Однако это совсем не означает, что предварительные оценки величины неустранимой погрешности не нужны. Достоверная информация о порядке величины  $\delta_{\text{н}y}$  позволяет осознанно выбрать метод решения задачи и разумно задать его точность. Желательно, чтобы величина погрешности метода была в 2—10 раз меньше неустранимой погрешности. Большее значение  $\delta_{\text{м}y}$  ощутимо снижает точность результата, меньшее — обычно требует увеличения затрат, практически уже не влияя на значение полной погрешности. Иногда характер использования результата таков, что вполне допустимо, чтобы величина  $\delta_{\text{м}y}$  была сравнима с  $\delta_{\text{н}y}$  или даже несколько превышала ее.

Величина вычислительной погрешности (при фиксированных модели, входных данных и методе решения) в основном определяется характеристиками используемой ЭВМ. Желательно, чтобы величина  $\delta_{\text{в}y}$  была хотя бы на порядок меньше величины погрешности метода и совсем не желательна ситуация, когда она существенно ее превышает.

Умение анализировать погрешности при решении прикладной задачи и соблюдать между ними разумный компромисс позволяет существенно экономить используемые ресурсы и является признаком высокой квалификации.

## § 2.2. Приближенные числа.

### Абсолютная и относительная погрешности

В предыдущем параграфе было отмечено, что числа, получаемые при решении на ЭВМ прикладных задач, как правило, являются

приближенными. Следовательно, вопрос о *точности* результатов, т.е. о мере их отклонения от истинных значений, в теории и практике методов вычислений приобретает особое значение. Начнем его рассмотрение с введения основных понятий элементарной теории погрешностей.

Условимся относительно обозначений, которые в дальнейшем будут использоваться при сравнении величин. Кроме привычных знаков " $=$ ", " $\neq$ ", " $<$ ", " $\leq$ ", будем использовать знаки приближенного равенства " $\approx$ " и приближенного неравенства " $<$ ". В случае, когда положительные величины  $a$  и  $b$  являются величинами одного порядка (т.е.  $10^{-1} \leq a/b \leq 10$ ), будем использовать обозначение  $a \sim b$ . Если же  $a$  много меньше  $b$ , то будем писать  $a \ll b$ , что эквивалентно соотношению  $a/b \ll 1$ .

**1. Абсолютная и относительная погрешности.** Пусть  $a$  — точное (вообще говоря, неизвестное) значение некоторой величины,  $a^*$  — известное приближенное значение той же величины (*приближенное число*). *Ошибкой* (или *погрешностью*) приближенного числа  $a^*$  называют разность  $a - a^*$  между точным и приближенным значениями.

Простейшей количественной мерой ошибки является *абсолютная погрешность*

$$\Delta(a^*) = |a - a^*|. \quad (2.1)$$

Однако по величине абсолютной погрешности далеко не всегда можно сделать правильное заключение о качестве приближения. Действительно, если  $\Delta(a^*) = 0.1$ , то следует ли считать погрешность большой или нужно признать ее малой? Ответ существенным образом зависит от принятых единиц измерения и масштабов величин. Если  $a \approx 0.3$ , то скорее всего точность приближения невелика; если же  $a \approx 3 \cdot 10^8$ , то следует признать точность очень высокой. Таким образом, естественно соотнести погрешность величины и ее значение, для чего вводится понятие *относительной погрешности* (при  $a \neq 0$ )

$$\delta(a^*) = \frac{|a - a^*|}{|a|} = \frac{\Delta(a^*)}{|a|}. \quad (2.2)$$

Использование относительных погрешностей удобно, в частности, тем, что они не зависят от масштабов величин и единиц измерения. Заметим, что для приведенного выше примера  $\delta(a^*) \approx 0.33 = 33\%$  в первом случае и  $\delta(a^*) \approx 0.33 \cdot 10^{-9} = 0.33 \cdot 10^{-7}\%$  во втором.

Так как значение  $a$  неизвестно, то непосредственное вычисление величин  $\Delta(a^*)$  и  $\delta(a^*)$  по формулам (2.1), (2.2) невозможно. Более

реальная и часто поддающаяся решению задача состоит в получении оценок погрешности вида

$$|a - a^*| \leq \bar{\Delta}(a^*), \quad (2.3)$$

$$\frac{|a - a^*|}{|a|} \leq \bar{\delta}(a^*), \quad (2.4)$$

где  $\bar{\Delta}(a^*)$  и  $\bar{\delta}(a^*)$  — известные величины, которые мы будем называть *вертними границами* (или просто *границами*) *абсолютной и относительной погрешностей*.

Если величина  $\bar{\Delta}(a^*)$  известна, то неравенство (2.4) будет выполнено, если положить

$$\bar{\delta}(a^*) = \frac{\bar{\Delta}(a^*)}{|a|}. \quad (2.5)$$

Точно так же если величина  $\bar{\delta}(a^*)$  известна, то следует положить

$$\bar{\Delta}(a^*) = |a| \bar{\delta}(a^*). \quad (2.6)$$

Поскольку значение  $a$  неизвестно, при практическом применении формулы (2.5), (2.6) заменяют приближенными равенствами

$$\bar{\delta}(a^*) \approx \frac{\bar{\Delta}(a^*)}{|a^*|}, \quad \bar{\Delta}(a^*) \approx |a^*| \bar{\delta}(a^*). \quad (2.7)$$

**З а м е ч а н и е.** В литературе по методам вычислений широко используется термин "точность". Принято говорить о точности входных данных и решения, о повышении и снижении точности вычислений и т.д. Мы также будем использовать эту терминологию, за которой скрывается довольно простой смысл. Точность в качественных рассуждениях обычно выступает как противоположность погрешности, хотя для количественного их измерения используются одни и те же характеристики (например, абсолютная и относительная погрешности). Точное значение величины — это значение, не содержащее погрешности. Повышение точности воспринимается как уменьшение погрешности, а снижение точности — как увеличение погрешности. Часто используемая фраза "требуется найти решение с заданной точностью  $\varepsilon$ " означает, что ставится задача о нахождении приближенного решения, принятая мера погрешности которого не превышает заданной величины  $\varepsilon$ . Вообще говоря, следовало бы говорить об абсолютной точности и относительной точности, но часто этого не делают, считая, что из контекста ясно, как измеряется величина погрешности.

**2. Правила записи приближенных чисел.** Пусть приближенное число  $a^*$  задано в виде конечной десятичной дроби:

$$a^* = \alpha_n \alpha_{n-1} \dots \alpha_0 . \beta_1 \beta_2 \dots \beta_m.$$

*Значащими цифрами* числа  $a^*$  называют все цифры в его записи, начиная с первой ненулевой слева.

**Пример 2.1.** У чисел  $a^* = 0.01\underline{03}$  и  $a^* = 0.01\underline{03000}$  значащие цифры подчеркнуты. Первое число имеет 3, а второе — 6 значащих цифр.

Значащую цифру числа  $a^*$  называют *верной*, если абсолютная погрешность числа не превосходит единицы разряда, соответствующего этой цифре.

**Пример 2.2.** Если  $\bar{\Delta}(a^*) = 2 \cdot 10^{-6}$ , то число  $a^* = 0.01\underline{03000}$  имеет 4 верные значащие цифры (они подчеркнуты).

Следует отметить, что широко распространенной ошибкой при записи приближенных чисел является отбрасывание последних значащих нулей (даже если они представляют собой верные цифры).

**З а м е ч а н и е.** Верная цифра приближенного числа, вообще говоря, не обязана совпадать с соответствующей цифрой в записи точного числа. Таким образом, термин "верная цифра" не следует понимать буквально (см. пример 2.3).

**Пример 2.3.** Пусть  $a = 1.00000$ ,  $a^* = 0.\underline{99999}$ . Тогда  $\Delta(a^*) = 0.00001$  и у числа  $a^*$  все подчеркнутые цифры — верные, хотя они и не совпадают с соответствующими цифрами числа  $a$ .

Количество верных значащих цифр числа тесно связано с величиной его относительной погрешности. Приведенные ниже утверждения позволяют в дальнейшем связывать точность числа с количеством его верных значащих цифр и трактовать потерю точности как потерю верных цифр.

**П р е д л о ж е н и е 2.1.** 1°. Если число  $a^*$  содержит  $N$  верных значащих цифр, то справедливо неравенство  $\delta(a^*) \leq (10^{N-1} - 1)^{-1} \approx \approx 10^{-N+1}$ .

2°. Для того чтобы число  $a^*$  содержало  $N$  верных значащих цифр, достаточно, чтобы было выполнено неравенство  $\delta(a^*) \leq (10^N + 1)^{-1} \approx \approx 10^{-N}$ .



3°. Если число  $a^*$  имеет ровно  $N$  верных значащих цифр, то  $10^{-N-1} < \delta(a^*) < 10^{-N}$  и таким образом  $\delta(a^*) \sim 10^{-N}$ .

**Пример 2.4.** Что можно сказать об относительной погрешности числа  $a^*$ , если оно содержит 3 верные цифры?

В силу утверждения 1° имеем  $\delta(a^*) < 10^{-2} = 1\%$ .

**Пример 2.5.** С какой относительной точностью следует найти число  $a^*$ , чтобы верными оказались 6 значащих цифр?

Из утверждения 2° следует, что достаточно найти  $a^*$  с относительной точностью  $\epsilon \approx 10^{-6}$ .

Заметим, что границы абсолютной и относительной погрешностей принято записывать с одной или двумя значащими цифрами. Бóльшая точность в записи этих величин, как правило, не имеет смысла, так как обычно они являются довольно грубыми оценками истинных значений погрешностей, и кроме того, для практического использования часто бывает достаточно знать только их порядок.

**Пример 2.6.** Информация о погрешности вида  $\delta(a^*) \approx 0.288754 \cdot 10^{-5}$  практически равноценна информации  $\delta(a^*) \approx 3 \cdot 10^{-6}$ , причем последняя вызывает больше доверия. Скорее всего, вполне удовлетворительной в данном случае является и запись  $\delta(a^*) \sim 10^{-6}$ .

Неравенство (2.3) эквивалентно двойному неравенству

$$a^* - \bar{\Delta}(a^*) \leq a \leq a^* + \bar{\Delta}(a^*)$$

и поэтому тот факт, что число  $a^*$  является приближенным значением числа  $a$  с верхней границей абсолютной погрешности  $\bar{\Delta}(a^*)$  (с абсолютной точностью  $\epsilon = \bar{\Delta}(a^*)$ ), принято записывать в виде

$$a = a^* \pm \bar{\Delta}(a^*).$$

Как правило, числа  $a^*$  и  $\bar{\Delta}(a^*)$  указывают с одинаковым числом цифр после десятичной точки.

**Пример 2.7.** Пусть для числа  $a$  известны приближенное значение  $a^* = 1.648$  и граница абсолютной погрешности  $\bar{\Delta}(a^*) = 0.002832$ . Тогда можно записать  $a = 1.648 \pm 0.003$ . Записи вида  $a = 1.648 \pm 0.002832$  или  $a = 1.648 \pm 0.1$  являются неестественными.

Из неравенства (2.4) следует, что значение  $a$  заключено примерно между  $a^*(1 - \bar{\delta}(a^*))$  и  $a^*(1 + \bar{\delta}(a^*))$ . Поэтому тот факт, что число  $a^*$  является приближенным значением числа  $a$  с границей относительной погрешности  $\bar{\delta}(a^*)$  (с *относительной точностью*  $\varepsilon = \bar{\delta}(a^*)$ ), принято записывать в виде  $a = a^*(1 \pm \bar{\delta}(a^*))$ .

**Пример 2.8.** Оценим точность часто используемого в простейших расчетах приближения  $\pi^* = 3.14$  к числу  $\pi$ . Известно, что  $\pi = 3.14159\dots$ , поэтому  $\pi - \pi^* = 0.00159\dots$ . Следовательно, можно принять  $\bar{\Delta}(\pi^*) = 0.0016$  и  $\bar{\delta}(\pi^*) \approx 0.0016/3.14 \approx 0.00051 = 0.051\%$ . Итак,  $\pi = 3.14 (1 \pm 0.051\%)$ .

**З а м е ч а н и е.** Если число  $a^*$  приводится в качестве результата без указания величины погрешности, то принято считать, что все его значащие цифры являются верными. Начинаящий пользователь часто слишком доверяет выводимым из ЭВМ цифрам, предполагая, что вычислительная машина придерживается того же соглашения. Однако это совсем не так: число может быть выведено с таким количеством значащих цифр, сколько потребует программист заданием соответствующего формата. Как правило, среди этих цифр только небольшое число первых окажутся верными, а, возможно, верных цифр нет совсем. Анализировать результаты вычислений и определять степень их достоверности совсем непросто. Одна из целей изучения вычислительных методов и состоит в достижении понимания того, что можно и чего нельзя ожидать от результатов, полученных на ЭВМ.

**3. Округление.** Часто возникает необходимость в *округлении* числа  $a$ , т.е. в замене его другим числом  $a^*$  с меньшим числом значащих цифр. Возникающая при такой замене погрешность называется *погрешностью округления*.

Существует несколько способов округления числа до  $n$  значащих цифр. Наиболее простой из них — *усечение* состоит в отбрасывании всех цифр, расположенных справа от  $n$ -й значащей цифры. Более предпочтительным является *округление по дополнению*. В простейшем варианте это правило округления состоит в следующем. Если первая слева из отбрасываемых цифр меньше 5, то сохраняемые цифры остаются без изменения. Если же она больше либо равна 5, то в младший сохраняемый разряд добавляется единица.

Абсолютная величина погрешности округления при округлении по дополнению не превышает половины единицы разряда, соответствующего последней оставляемой цифре, а при округлении усечением — единицы того же разряда.

**Пример 2.9.** При округлении числа  $a = 1.72631$  усечением до трех значащих цифр получится число  $a^* = 1.72$ , а при округлении по дополнению — число  $a^* = 1.73$ .

Границы абсолютной и относительной погрешностей принято всегда округлять в сторону увеличения.

**Пример 2.10.** Округление величин  $\bar{\Delta}(a^*) = 0.003721$  и  $\bar{\delta}(a^*) = 0.0005427$  до двух значащих цифр дает значения  $\bar{\Delta}(a^*) = 0.0038$  и  $\bar{\delta}(a^*) = 0.00055$ .

### § 2.3. Погрешности арифметических операций над приближенными числами

Исследуем влияние погрешностей исходных данных на погрешность результатов арифметических операций. Пусть  $a^*$  и  $b^*$  — приближенные значения чисел  $a$  и  $b$ . Какова соответствующая им величина неустранимой погрешности результата?

**Предложение 2.2.** Абсолютная погрешность алгебраической суммы (суммы или разности) не превосходит суммы абсолютных погрешностей слагаемых, т.е.

$$\Delta(a^* \pm b^*) \leq \Delta(a^*) + \Delta(b^*). \quad (2.8)$$

□ Имеем

$$\begin{aligned} \Delta(a^* \pm b^*) &= |(a \pm b) - (a^* \pm b^*)| = |(a - a^*) \pm (b - b^*)| \leq \\ &\leq \Delta(a^*) + \Delta(b^*). \quad \blacksquare \end{aligned}$$

**С л е д с т в и е.** В силу неравенства (2.8) естественно положить

$$\bar{\Delta}(a^* \pm b^*) = \bar{\Delta}(a^*) + \bar{\Delta}(b^*). \quad (2.9)$$

Оценим относительную погрешность алгебраической суммы.

**Предложение 2.3.** Пусть  $a$  и  $b$  — ненулевые числа одного знака. Тогда справедливы неравенства

$$\delta(a^* + b^*) \leq \delta_{\max}, \quad \delta(a^* - b^*) \leq \nu \delta_{\max}, \quad (2.10)$$

где  $\delta_{\max} = \max \{ \delta(a^*), \delta(b^*) \}$ ,  $\nu = |a + b| / |a - b|$ .

□ Используя формулу (2.2) и неравенство (2.8), имеем

$$|a \pm b| \delta(a^* \pm b^*) = \Delta(a^* \pm b^*) \leq \Delta(a^*) + \Delta(b^*) = \\ = |a| \delta(a^*) + |b| \delta(b^*) \leq (|a| + |b|) \delta_{\max} = |a + b| \delta_{\max}.$$

Из полученного неравенства сразу следуют оценки (2.10). ■

**С л е д с т в и е.** В силу неравенств (2.10) естественно положить

$$\bar{\delta}(a^* + b^*) = \bar{\delta}_{\max}, \quad \bar{\delta}(a^* - b^*) = \nu \bar{\delta}_{\max}, \quad (2.11)$$

где  $\bar{\delta}_{\max} = \max \{\bar{\delta}(a^*), \bar{\delta}(b^*)\}$ ,  $\nu = |a + b|/|a - b|$ .

Первое из равенств (2.11) означает, что при суммировании чисел одного знака не происходит потери точности, если оценивать точность в относительных единицах. Совсем иначе обстоит дело при вычитании чисел одного знака. Здесь граница относительной ошибки возрастает в  $\nu > 1$  раз и возможна существенная потеря точности. Если числа  $a$  и  $b$  близки настолько, что  $|a + b| \gg |a - b|$ , то  $\nu \gg 1$  и не исключена полная или почти полная потеря точности. Когда это происходит, говорят о том, что произошла *катастрофическая потеря точности*.

**Пример 2.11.** Пусть решается инженерная задача, в которой окончательный результат  $y$  вычисляется по формуле  $y = 1 - x$  с помощью предварительно определяемого значения  $x$ . Предположим, что найденное приближение  $x^* = 0.999997$  к значению  $x$  содержит 6 верных значащих цифр. Тогда  $y^* = 1 - 0.999997 = 0.000003$  и в процессе вычисления оказались потерянными 5 верных цифр. Если же учесть, что  $\delta(x^*) \sim 0.0001\%$ , а  $\delta(y^*) \sim 33\%$ , то следует признать, что произошла катастрофическая потеря точности.

Подчеркнем, что здесь виновником "катастрофы" является не операция вычитания, а предложенный метод решения задачи, где окончательный результат получается с помощью вычитания двух близких чисел. Выполнение этой операции лишь делает очевидным то, что действительно полезная информация о значении  $y$  уже оказалась потерянной до вычитания. Если нет другого варианта расчета, то для получения приемлемого результата следовало бы предварительно вычислить  $x$  с существенно большим числом верных знаков, учитывая, что 5 старших значащих цифр при вычитании будут потеряны.

Итак, получаем следующий важный вывод. При построении численного метода решения задачи следует избегать вычитания близких чисел одного знака. Если же такое вычитание неизбежно, то следует вычислять аргументы с повышенной точностью, учитывая ее потерю примерно в  $\nu = |a + b|/|a - b|$  раз.

**П р е д л о ж е н и е 2.4.** Для относительных погрешностей произведения и частного приближенных чисел верны оценки

$$\delta(a^*b^*) \leq \delta(a^*) + \delta(b^*) + \delta(a^*)\delta(b^*), \quad (2.12)$$

$$\delta(a^*/b^*) \leq \frac{\delta(a^*) + \delta(b^*)}{1 - \delta(b^*)}, \quad (2.13)$$

в последней из которых считается, что  $\delta(b^*) < 1$ .

□ Выполним следующие преобразования:

$$\begin{aligned} |ab| \delta(a^*b^*) &= \Delta(a^*b^*) = |ab - a^*b^*| = |(a - a^*)b + \\ &+ (b - b^*)a - (a - a^*)(b - b^*)| \leq |b| \Delta(a^*) + |a| \Delta(b^*) + \\ &+ \Delta(a^*) \Delta(b^*) = |ab| (\delta(a^*) + \delta(b^*) + \delta(a^*)\delta(b^*)), \end{aligned}$$

т.е.

$$|ab| \delta(a^*b^*) \leq |ab| (\delta(a^*) + \delta(b^*) + \delta(a^*)\delta(b^*)).$$

Разделив обе части этого неравенства на  $|ab|$ , получаем оценку (2.12).

Для вывода второй оценки предварительно заметим, что  $|b^*| = |b + (b^* - b)| \geq |b| - \Delta(b^*) = |b|(1 - \delta(b^*))$ . Тогда

$$\begin{aligned} \delta(a^*/b^*) &= \frac{|a/b - a^*/b^*|}{|a/b|} = \frac{|ab^* - ba^*|}{|ab^*|} = \\ &= \frac{|a(b^* - b) + b(a - a^*)|}{|ab^*|} \leq \frac{|a| \Delta(b^*) + |b| \Delta(a^*)}{|ab| (1 - \delta(b^*))} = \\ &= \frac{\delta(b^*) + \delta(a^*)}{1 - \delta(b^*)}. \blacksquare \end{aligned}$$

**С л е д с т в и е.** Если  $\bar{\delta}(a^*) \ll 1$  и  $\bar{\delta}(b^*) \leq 1$ , то для оценки границ относительных погрешностей можно использовать следующие приближенные равенства:

$$\bar{\delta}(a^*b^*) \approx \bar{\delta}(a^*) + \bar{\delta}(b^*), \quad \bar{\delta}(a^*/b^*) \approx \bar{\delta}(a^*) + \bar{\delta}(b^*). \quad (2.14)$$

Именно равенства (2.14) чаще всего и используют для практической оценки погрешности.

Итак, выполнение арифметических операций над приближенными числами, как правило, сопровождается потерей точности. Единственная операция, при которой потеря не происходит, — это сложение чисел одного знака. Наибольшая потеря точности может произойти при вычитании близких чисел одного знака.

## § 2.4. Погрешность функции

**1. Погрешность функции многих переменных.** Пусть  $f(x) = f(x_1, x_2, \dots, x_m)$  — дифференцируемая в области  $G$  функция  $m$  переменных, вычисление которой производится при приближенно заданных значениях аргументов  $x_1^*, x_2^*, \dots, x_m^*$ . Такая ситуация возникает, например, всякий раз, когда на ЭВМ производится расчет по формуле. Важно знать, какова величина неустранимой ошибки, вызванной тем, что вместо значения  $y = f(x)$  в действительности вычисляется значение  $y^* = f(x^*)$ , где  $x^* = (x_1^*, x_2^*, \dots, x_m^*)$ .

Введем обозначения: пусть  $[x, x^*]$  — отрезок<sup>1</sup>, соединяющий точки  $x$  и  $x^*$ , и  $f'_{x_j} = \partial f / \partial x_j$ .

**Предложение 2.5.** Для абсолютной погрешности значения  $y^* = f(x^*)$  справедлива следующая оценка:

$$\Delta(y^*) \leq \sum_{j=1}^m \max_{[x, x^*]} |f'_{x_j}| \Delta(x_j^*). \quad (2.15)$$

□ Оценка (2.15) вытекает из формулы конечных приращений Лагранжа<sup>2</sup>:

$$f(x) - f(x^*) = \sum_{j=1}^m f'_{x_j}(\tilde{x})(x_j - x_j^*), \quad \tilde{x} \in [x, x^*]. \blacksquare$$

**Следствие.** Если  $x^* \approx x$ , то в силу оценки (2.15) можно положить

$$\bar{\Delta}(y^*) \approx \sum_{j=1}^m |f'_{x_j}(x^*)| \bar{\Delta}(x_j^*), \quad (2.16)$$

$$\bar{\Delta}(y^*) \approx \sum_{j=1}^m |f'_{x_j}(x)| \bar{\Delta}(x_j^*). \quad (2.17)$$

Равенство (2.16) удобно для практических оценок, а равенством (2.17) мы воспользуемся в дальнейшем для теоретических построений.

<sup>1</sup> Отрезком, соединяющим точки  $x$  и  $x^*$  в  $m$ -мерном пространстве, называется множество точек вида  $\alpha x + (1 - \alpha)x^*$ ,  $0 \leq \alpha \leq 1$ .

<sup>2</sup> Жозеф Луи Лагранж (1736 — 1813) — французский математик, механик и астроном. Один из создателей математического анализа, вариационного исчисления, классической аналитической механики.

Из формул (2.16), (2.17) вытекают приближенные равенства для оценки границ относительных погрешностей:

$$\bar{\delta}(y^*) \approx \sum_{j=1}^m \nu_j^* \bar{\delta}(x_j^*), \quad \bar{\delta}(y^*) \approx \sum_{j=1}^m \nu_j \bar{\delta}(x_j^*). \quad (2.18)$$

Здесь

$$\nu_j^* = \frac{|x_j^*| |f'_j(x_j^*)|}{|f(x_j^*)|}, \quad \nu_j = \frac{|x_j| |f'_j(x)|}{|f(x)|}. \quad (2.19)$$

**Пример 2.12.** Пусть корни квадратного уравнения  $x^2 + bx + c = 0$  вычисляются при значениях коэффициентов  $b \approx 10^3$ ,  $c \approx 1$ . Каково влияние погрешностей задания коэффициентов на точность вычисляемых значений?

Воспользуемся явными формулами для корней:  $x_1 = f(b, c) = (-b - \sqrt{d})/2$ ,  $x_2 = g(b, c) = (-b + \sqrt{d})/2$ , где  $d = b^2 - 4c$ . Заметим, что  $x_1 \cdot x_2 = c$ . Тогда при заданных значениях коэффициентов получим  $\sqrt{d} \approx \sqrt{10^6 - 4} \approx 10^3$ ,  $x_1 \approx (-10^3 - 10^3)/2 = -10^3$ ,  $x_2 = c/x_1 \approx 1/(-10^3) = -10^{-3}$ . Далее, имеем  $f'_b = (-1 - b/\sqrt{d})/2 \approx (-1 - 10^3/10^3)/2 = -1$ ,  $f'_c = 1/\sqrt{d} \approx 10^{-3}$ ,  $g'_b = (-1 + b/\sqrt{d})/2 = (b - \sqrt{d})/(2\sqrt{d}) = -x_2/\sqrt{d} \approx 10^{-6}$ ,  $g'_c = -1/\sqrt{d} \approx -10^{-3}$ . Применяя первую из формул (2.19), для корня  $x_1$  находим  $\nu_{1,1}^* = |b^*| |f'_b| / |x_1^*| \approx 1$ ,  $\nu_{2,1}^* = |c^*| |f'_c| / |x_1^*| \approx 10^{-6}$ . Аналогично для корня  $x_2$  имеем  $\nu_{2,1}^* = |b^*| |g'_b| / |x_2^*| \approx 1$ ,  $\nu_{2,2}^* = |c^*| |g'_c| / |x_2^*| \approx 1$ . Таким образом,

$$\bar{\delta}(x_1^*) \approx \bar{\delta}(b^*) + 10^{-6} \bar{\delta}(c^*), \quad \bar{\delta}(x_2^*) \approx \bar{\delta}(b^*) + \bar{\delta}(c^*). \quad (2.20)$$

Следовательно, точность первого корня практически определяется только точностью задания коэффициента  $b$ , в то время как коэффициент  $c$  может быть задан очень грубо. Для второго корня влияние погрешностей в задании коэффициентов  $b$  и  $c$  практически одинаково.

**2. Погрешность функции одной переменной.** Формулы для границ погрешностей функции  $f(x)$  одной переменной являются частным случаем формул (2.16) — (2.18) при  $m = 1$ :

$$\bar{\Delta}(y^*) \approx |f'(x^*)| \bar{\Delta}(x^*), \quad \bar{\Delta}(y^*) \approx |f'(x)| \bar{\Delta}(x^*), \quad (2.21)$$

$$\bar{\delta}(y^*) \approx \nu^* \bar{\delta}(x^*), \quad \bar{\delta}(y^*) \approx \nu \bar{\delta}(x^*), \quad (2.22)$$

где  $\nu^* = |x^*| |f'(x^*)| / |f(x^*)|$ ,  $\nu = |x| |f'(x)| / |f(x)|$ .

**3. Погрешность неявной функции.** Нередко приходится сталкиваться с ситуацией, когда функция  $y = f(x_1, x_2, \dots, x_m)$  задается не явной формулой, а как решение нелинейного уравнения  $F(y, x_1, x_2, \dots, x_m) = 0$ , т.е. неявно. Если для такой неявной функции воспользоваться известными формулами вычисления производных

$$f'_{x_j}(x) = (-F'_{x_j} / F'_y) \Big|_{y=f(x)}, \quad j = 1, 2, \dots, m, \quad (2.23)$$

то исследование неустранимой погрешности неявной функции сразу же сводится к рассмотренному выше случаю.

**Пример 2.13.** Для проведенного в примере 2.12 исследования совсем не обязательно было выписывать явные формулы для корней. В этом случае величины  $x_1 = f(b, c)$  и  $x_2 = g(b, c)$  можно рассматривать как неявные функции, заданные уравнением  $F(x, b, c) = 0$ , где  $F = x^2 + bx + c$ .

Здесь  $F'_x = 2x + b$ ,  $F'_b = x$ ,  $F'_c = 1$ . Следовательно,

$$\nu_{1,i}^* = (|b| |F'_b / F'_x| / |x|) \Big|_{x=x_i^*, b=10^3, c=1} \approx 10^3 / |2x_i^* + 10^3|,$$

$$\nu_{2,i}^* = (|c| |F'_c / F'_x| / |x|) \Big|_{x=x_i^*, b=10^3, c=1} \approx 1 / |(2x_i^* + 10^3)x_i^*|.$$

Вычисления при  $i = 1$ ,  $x_1^* \approx -10^3$  и  $i = 2$ ,  $x_2^* \approx -10^{-3}$  дают те же значения коэффициентов  $\nu_{1,1}^*$ ,  $\nu_{1,2}^*$ ,  $\nu_{2,1}^*$ ,  $\nu_{2,2}^*$ , что и в примере 2.12, а, следовательно, те же формулы (2.20).

## § 2.5. Особенности машинной арифметики

Знание основных особенностей машинной арифметики необходимо для грамотного использования ЭВМ при решении научно-технических задач. Пользователь, не учитывающий эти особенности, вряд ли может рассчитывать на высокую точность и эффективность вычислений. Невнимание к ним часто приводит к неверным результатам. Подчеркнем, что в основе причин появления вычислительной погрешности лежит сам способ представления чисел на ЭВМ.



1. **Системы счисления.** Принятый способ записи чисел состоит в представлении их упорядоченным набором цифр. В привычной нам десятичной позиционной системе счисления вещественное число  $x$  представляют последовательностью символов, которая начинается со знака (+ или -) и продолжается цепочкой десятичных цифр  $\alpha_i$  и  $\beta_j$ , разделенных десятичной точкой:

$$x = \pm \alpha_n \dots \alpha_1 \alpha_0 . \beta_1 \beta_2 \dots \beta_m \dots \quad (2.24)$$

Здесь каждой позиции (разряду), которую занимает цифра относительно десятичной точки, отвечает определенная степень числа 10. По существу, равенство (2.24) представляет собой принятое сокращение полной записи числа  $x$ , имеющей вид

$$x = \pm (\alpha_n \cdot 10^n + \dots + \alpha_1 \cdot 10^1 + \alpha_0 \cdot 10^0 + \beta_1 \cdot 10^{-1} + \beta_2 \cdot 10^{-2} + \dots + \beta_m \cdot 10^{-m} + \dots).$$

**Пример 2.14.** Запись  $x = 20.5$  означает, что  $x = 2 \cdot 10^1 + 0 \cdot 10^0 + 5 \cdot 10^{-1}$ .

Для представления чисел в вычислительных машинах также используют позиционные системы счисления, однако основаниями систем служат, как правило, степени числа 2. Это вызвано способом хранения чисел в устройствах памяти ЭВМ, каждое из которых можно рассматривать как набор однотипных элементов, способных находиться только в одном из двух возможных устойчивых состояний — "включен" или "выключен". Эти состояния интерпретируются соответственно как 0 или 1 — значения двоичного числа. Наиболее распространены системы счисления с основанием 2 (базисная двоичная система счисления), 8 и 16.

Игнорируя некоторые малосущественные детали, будем считать, что все вычислительные машины работают в двоичной системе счисления. В ней вещественное число  $x$  по-прежнему записывается в виде (2.24), однако  $\alpha_i$  и  $\beta_j$  — уже двоичные цифры (0 или 1). В этом случае полная запись выглядит так:

$$x = \pm (\alpha_n \cdot 2^n + \dots + \alpha_1 \cdot 2^1 + \alpha_0 \cdot 2^0 + \beta_1 \cdot 2^{-1} + \beta_2 \cdot 2^{-2} + \dots + \beta_m \cdot 2^{-m} + \dots).$$

**Пример 2.15.** Запишем число  $x = 20.5$  в двоичной системе счисления. Для этого разложим его в сумму по степеням двойки:  $x = 1 \cdot 2^4 + 0 \cdot 2^3 + 1 \cdot 2^2 + 0 \cdot 2^1 + 0 \cdot 2^0 + 1 \cdot 2^{-1}$ . Опуская степени двойки, получаем  $x = (10100.1)_2$ . Здесь нижний индекс 2 указывает на основание системы счисления.

Для хранения числа в памяти ЭВМ отводится поле стандартной длины (*машинное слово*), в котором число записывают в виде последовательности двоичных цифр. По форме представления, способу хранения и реализации арифметических операций существенно различаются два типа используемых на вычислительных машинах чисел: целые числа и вещественные числа.

**2. Представление целых чисел.** Целое число  $n$  представляют в виде

$$n = \pm(\alpha_L 2^L + \dots + \alpha_1 2^1 + \alpha_0 2^0), \quad (2.25)$$

где  $L$  — некоторое стандартное для ЭВМ целое число,  $\alpha_i$  — двоичные цифры. Всего для хранения числа  $n$  отводят  $L + 2$  разрядов (один из них для хранения знака).

Из представления (2.25) видно, что максимальное по модулю целое число, представимое в ЭВМ, есть  $n_{\max} = 2^L + \dots + 2^1 + 2^0 = 2^{L+1} - 1$ . Обычно это значение не очень велико. Например, при стандартном формате записи целых чисел на компьютерах типа IBM PC  $n_{\max} = 2^{31} - 1 \approx 2 \cdot 10^9$ .

Операции сложения, вычитания и умножения над целыми числами реализованы так, что если результат не превышает по модулю число  $n_{\max}$ , то он получается точным. Отметим, однако, следующую неприятную особенность. Если модуль результата превышает  $n_{\max}$ , то на большинстве вычислительных машин эта ситуация не доводится до сведения пользователя, происходит присвоение результату некоторого значения (меньшего  $n_{\max}$  по модулю) и вычисления продолжают далее.

**3. Представление вещественных чисел.** В большинстве современных ЭВМ для вещественных чисел принята форма представления с плавающей точкой, когда каждое число представляют в виде

$$x = \pm(\gamma_1 \cdot 2^{-1} + \gamma_2 \cdot 2^{-2} + \dots + \gamma_t \cdot 2^{-t}) 2^p. \quad (2.26)$$

Здесь  $\gamma_1, \gamma_2, \dots, \gamma_t$  — двоичные цифры. Число  $x$  нормализуется так, чтобы  $\gamma_1 = 1$ , и поэтому в памяти ЭВМ хранятся только значащие цифры. Число  $\mu = \pm(\gamma_1 \cdot 2^{-1} + \gamma_2 \cdot 2^{-2} + \dots + \gamma_t \cdot 2^{-t})$  называется *мантиссой* числа  $x$ . Количество  $t$  цифр, которое отводится для записи мантиссы, называемое *разрядностью* мантиссы, зависит от конструктивных особенностей конкретной вычислительной машины, но всегда является конечным. В представлении (2.26)  $p$  — целое число, называемое *двоичным порядком*. Порядок также записывают как двоичное целое число  $p = \pm(\sigma_l \sigma_{l-1} \dots \sigma_0)_2$ , для хранения которого в машинном слове отводится  $l + 2$  двоичных разрядов. На рис. 2.1 схематически представлена структура машинного слова для хранения вещественного числа.




Рис. 2.1

Поскольку нуль — ненормализуемое число (его нельзя представить в виде (2.26) при  $\gamma_1 \neq 0$ ), для его хранения предусматривают особый способ записи.

**Пример 2.16.** Представим число  $x = 20.5$  в двоичной системе счисления в нормализованной форме с плавающей точкой. Так как  $x = (10100.1)_2$  (см. пример 2.15), то, перемещая двоичную точку на 5 позиций влево, получаем  $x = (0.101001)_2 \cdot 2^5$ .

На основании имеющихся сведений о представлении чисел в ЭВМ можно сделать ряд важных выводов.

1<sup>0</sup>. На ЭВМ представимы не все числа, а лишь конечный набор рациональных чисел специального вида. Эти числа образуют *представимое множество* вычислительной машины. Для всех остальных чисел  $x$  возможно лишь их приближенное представление с ошибкой, которую принято называть *ошибкой представления* (или *ошибкой округления*). Обычно приближенное представление числа  $x$  в ЭВМ обозначают<sup>1</sup> как  $x^* = \text{fl}(x)$ . Если округление производят по дополнению, то граница относительной погрешности представления равна единице первого отброшенного разряда мантиссы, т.е.  $\bar{\delta}(x^*) = \epsilon_m = 2^{-t}$  (порядок числа не влияет на относительную погрешность представления). Если же округление производят усечением, то  $\bar{\delta}(x^*) = \epsilon_m = 2^{1-t}$ . Величина  $\epsilon_m$  играет в вычислениях на ЭВМ фундаментальную роль; ее называют *относительной точностью ЭВМ*, а также *машинной точностью* (или *машинным эpsilon*). Всюду в дальнейшем  $\epsilon_m$  — это относительная точность ЭВМ. Заметим, что значение этой величины определяется разрядностью мантиссы и способом округления.

Важно с самого начала иметь четкое представление о том, что почти наверняка в представимом множестве ЭВМ нет числа  $y$ , являющегося решением поставленной задачи. Лучшее, что можно попытаться сделать, — это найти его представление  $y^* = \text{fl}(y)$  с относительной точностью порядка  $\epsilon_m$ .

<sup>1</sup> fl — начальные буквы англ. floating — "плавающий".

Полезно отметить, что среди представимых на ЭВМ чисел нет не только ни одного иррационального (в том числе и таких важных постоянных, как  $\pi$ ,  $e$ ,  $\sqrt{2}$ ), но и даже такого широко используемого в вычислениях числа, как 0.1. Дело в том, что двоичная запись числа 0.1 является бесконечной периодической дробью:  $0.1 = (0.0001100110011\dots)_2$ . Поэтому это число всегда представляется на ЭВМ приближенно, с погрешностью, вызванной необходимостью округления.

2°. Диапазон изменения чисел в ЭВМ ограничен. В самом деле, так как  $\gamma_1 = 1$ , то для мантиисы  $\mu$  справедливы оценки  $0.5 \leq |\mu| < 1$ . В то же время для представления в ЭВМ порядка  $p$  используется конечное число  $(l + 1)$  двоичных цифр и поэтому  $|p| \leq p_{\max} = 2^{l+1} - 1$ . Таким образом, для всех представимых на ЭВМ чисел  $x$  (за исключением нуля) имеем  $0 < X_0 \leq |x| < X_\infty$ , где  $X_0 = 2^{-(p_{\max}+1)}$ ,  $X_\infty = 2^{p_{\max}}$ . Заметим, что диапазон представления чисел на ЭВМ всецело определяется разрядностью порядка.

3°. Все числа  $x$ , по модулю большие  $X_\infty$ , не представимы на ЭВМ и могут рассматриваться как *машинная бесконечность*. Попытка получить такое число приводит к аварийному останову ЭВМ по *переполнению*. Все числа  $x$ , по модулю меньшие  $X_0$ , для вычислительной машины не различимы и представляются как нуль (*машинный нуль*). Получение числа  $x$  такого, что  $|x| < X_0$ , называют *исчезновением порядка* (или *антипереполнением*). Обычно при исчезновении порядка автоматически полагается  $\text{fl}(x) = 0$  и вычисления продолжаются.

**З а м е ч а н и е.** Не следует смешивать машинную точность  $\epsilon_m$  с минимальным положительным представимым на ЭВМ числом  $X_0$ . Это совершенно разные числа, причем  $X_0 \ll \epsilon_m$ .



Рис. 2.2

4°. На машинной числовой оси (рис. 2.2) числа расположены неравномерно. Плотность их возрастает по мере приближения к нулю и падает с удалением от нуля. Чтобы убедиться в этом, заметим, что

расстояние от одного представимого на ЭВМ числа  $x$  до другого ближайшего представимого равно единице последнего разряда мантиссы, умноженной на  $2^p$ , т.е. равно  $2^{p-t}$ . Так как  $t$  фиксировано, то расстояние уменьшается с уменьшением порядка  $p$  и возрастает с увеличением  $p$ .

Для компьютеров типа IBM PC (при вычислениях на ФОРТРАНЕ) представимые числа расположены в диапазоне  $10^{-38} < |x| < 3 \cdot 10^{38}$ , вполне достаточном для большинства приложений. Однако разрядность мантиссы невелика ( $t = 23$ ) и  $\varepsilon_m \approx 10^{-7}$ ; в десятичной арифметике это эквивалентно тому, что мантисса содержит 7 десятичных цифр. Заметим, что для большинства ЭВМ, используемых для научно-технических расчетов, мантисса имеет разрядность, эквивалентную 7—14 десятичным разрядам.

**4. Арифметические операции над числами с плавающей точкой.** Правила выполнения арифметических операций в двоичной системе счисления чрезвычайно просты и легко реализуются на ЭВМ.

Однако в силу ограниченной разрядности мантиссы операции сложения, вычитания, умножения и деления над представимыми в ЭВМ вещественными числами не могут быть реализованы точно. Дело в том, что арифметические операции над числами, мантиссы которых содержат  $t$  разрядов, приводят, как правило, к результатам, содержащим более  $t$  разрядов. Округление результата до  $t$  разрядов и служит главным источником погрешности. Для того чтобы отличать машинные арифметические операции от идеальных математических операций  $+$ ,  $-$ ,  $\times$ ,  $:$ , будем обозначать их через  $\oplus$ ,  $\ominus$ ,  $\otimes$ ,  $\oslash$ . Игнорируя несущественные детали, можно считать, что результат машинной арифметической операции совпадает с результатом точного выполнения той же операции с погрешностью, приближенно равной погрешности округления. Таким образом,

$$\bar{\Delta}(a \oplus b) \approx |a + b| \varepsilon_m, \quad \bar{\Delta}(a \ominus b) \approx |a - b| \varepsilon_m,$$

$$\bar{\Delta}(a \otimes b) \approx |a \times b| \varepsilon_m, \quad \bar{\Delta}(a \oslash b) \approx |a : b| \varepsilon_m.$$

Конечно, в некоторых ситуациях округление может отсутствовать. Например, полезно знать, что умножение и деление числа на целую степень двойки выполняется на ЭВМ точно, так как в этом случае мантисса не меняется.

**Пример 2.17.** Рассмотрим гипотетическую ЭВМ, в которой числа представляются всего лишь с 6 двоичными разрядами мантиссы, а округление производится по дополнению. Пусть на такой ЭВМ вычисляются сумма и произве-

деление двух представимых на ней чисел  $a = 20.5 = (10100.1)_2$  и  $b = 1.75 = (1.11)_2$ . Производим вычисления в двоичной арифметике:

$$\begin{aligned} a + b &= (10100.1)_2 + (1.11)_2 = (10110.01)_2, \\ a \times b &= (10100.1)_2 \times (1.11)_2 = (100011.111)_2. \end{aligned}$$

После округления до 6 значащих цифр получим  $a \oplus b = (10110.1)_2 = 22.5$ ,  $a \otimes b = (100100.)_2 = 36$ . Очевидно, что эти результаты отличаются от точных значений  $a + b = 22.25$ ,  $a \times b = 35.875$ .

Заметим, что машинные арифметические операции обладают иными свойствами, нежели обычные математические операции. Например, не выполняется известное правило арифметики "от перемены мест слагаемых сумма не меняется". Покажем это на примере.

**Пример 2.18.** Пусть вычисления производятся на ЭВМ из примера 2.17, причем  $a = (1.)_2$ ,  $b = c = (0.000001)_2$ . Тогда  $a + b = (1.000001)_2$  и после округления имеем  $a \oplus b = (1.00001)_2$ . Далее,  $(a \oplus b) + c = (1.000011)_2$  и после округления получим  $(a \oplus b) \oplus c = (1.00010)_2$ . Сложение в ином порядке дает  $c \oplus b = (0.000010)_2$ ,  $(c \oplus b) \oplus a = (1.00001)_2$ . Таким образом,  $(a \oplus b) \oplus c \neq (c \oplus b) \oplus a$ .

**5. Удвоенная точность.** На многих вычислительных машинах возможна реализация арифметических действий над числами, разрядность мантисс которых примерно вдвое превосходит стандартную разрядность  $t$ . Это приводит к существенному повышению машинной точности. Например, на компьютерах типа IBM PC (при вычислениях на ФОРТРАНЕ) в режиме удвоенной точности  $\epsilon_M \sim 10^{-16}$ . Для сравнения напомним, что обычная точность этих ЭВМ есть  $\epsilon_M \sim 10^{-7}$ , так что следует говорить не об удвоении точности, а о повышении точности на много порядков.

На тех ЭВМ, где арифметика удвоенной точности реализована аппаратно, время исполнения программ возрастает не более чем вдвое (часто этот коэффициент ближе к единице). Если же реализация вычислений с удвоенной мантиссой осуществляется программным образом, то время счета увеличивается в несколько раз. Поскольку для хранения числа с удвоенной мантиссой отводится два машинных слова, в этом случае вдвое возрастает используемая память.

Отметим, что удвоенная точность не ликвидирует ошибки округления, а только уменьшает их величину.

**6. Вычисление машинного эпсилон.** Для приближенного вычисления величины  $\epsilon_M$  удобно пользоваться следующим определением. Машинное эпсилон — это минимальное из представимых на ЭВМ чисел  $\epsilon$ , для которых  $1 \oplus \epsilon > 1$ .

Величину  $\epsilon_m$  можно оценить непосредственно в ходе вычислительного процесса. Для этого достаточно включить в программу фрагмент, реализующий следующий метод: Полагая  $\epsilon^{(0)} = 1$ , следует вычислять последовательно  $\epsilon^{(1)} = 0.5\epsilon^{(0)}$ ,  $\epsilon^{(2)} = 0.5\epsilon^{(1)}$ , ...,  $\epsilon^{(n)} = 0.5\epsilon^{(n-1)}$ , ..., проверяя каждый раз выполнение неравенства  $1 \oplus \epsilon^{(n)} > 1$ . Как только при некотором  $n$  окажется, что  $1 \oplus \epsilon^{(n)} = 1$ , следует положить  $\epsilon_m = \epsilon^{(n-1)}$  и перейти к следующему этапу вычислений. Хотя полученное таким способом значение может отличаться от  $\epsilon_m$  в 2 раза, обычно оно используется так, что эта погрешность не имеет значения.

**Пример 2.19.** Покажем, что  $\epsilon_m = 2^{-6} = (0.000001)_2$  — машинное эпсилон для ЭВМ из примера 2.17. В самом деле,  $1 + \epsilon_m = (1.000001)_2$  и после округления имеем  $1 \oplus \epsilon_m = (1.000001)_2$ . Если же к единице добавить любое положительное  $\epsilon < \epsilon_m$ , то в седьмом разряде результата будет стоять нуль и после округления получим  $1 \oplus \epsilon = 1$ .

Всюду в дальнейшем, приводя конкретные числовые примеры, мы откажемся от использования двоичной арифметики. Десятичная арифметика привычнее, а основные закономерности поведения ошибок округления не зависят от основания используемой системы. В большинстве расчетов, которые будут приведены для иллюстрации поведения ошибок округления, имитируется выполнение вычислений на гипотетической вычислительной машине, имеющей 6 десятичных разрядов мантиссы и производящей округление по дополнению. Будем называть эту машину *6-разрядной десятичной ЭВМ*. Для нее  $\epsilon_m = 5 \cdot 10^{-7}$ , так что по точности она сравнима с компьютером типа IBM PC (при вычислениях на ФОРТРАНЕ с обычной точностью).

## § 2.6. Дополнительные замечания

1. Более подробно приближенные числа и погрешности арифметических операций над ними изложены в известном учебном пособии [28]. Здесь же приведены правила подсчета оставляемых значащих цифр, которые рекомендуются применять при массовых "ручных" вычислениях без точного учета погрешностей.

2. Дополнительную информацию об особенностях арифметических операций над числами с плавающей точкой можно найти, например, в [19], [83].

3. В последнее время в практике вычислений в качестве меры ошибки приближенного числа  $a^*$  часто используют величину  $\frac{|a - a^*|}{1 + |a|}$ , объединяющую в себе черты абсолютной и относительной погрешности. Она близка к  $\Delta |a^*|$  при  $|a| \ll 1$  и практически совпадает с  $\delta(a^*)$  при  $|a| \gg 1$ .

## Глава 3

### ВЫЧИСЛИТЕЛЬНЫЕ ЗАДАЧИ, МЕТОДЫ И АЛГОРИТМЫ. ОСНОВНЫЕ ПОНЯТИЯ

#### § 3.1. Корректность вычислительной задачи

**1. Постановка вычислительной задачи.** Под вычислительной задачей будем понимать одну из трех задач, которые возникают при анализе математических моделей: прямую задачу, обратную задачу или задачу идентификации (см. § 1.2). Слово "вычислительная" подчеркивает, что основные усилия будут направлены на то, чтобы найти (вычислить) ее решение.

Будем считать, что постановка задачи включает в себя задание множества допустимых входных данных  $X$  и множества возможных решений  $Y$ . Цель вычислительной задачи состоит в нахождении решения  $y \in Y$  по заданному входному данному  $x \in X$ . Для простоты понимания достаточно ограничиться рассмотрением задач, в которых входные данные и решение могут быть только числами, наборами чисел (векторами, матрицами, последовательностями) и функциями. Предположим, что для оценки величин погрешностей приближенных входных данных  $x^*$  и приближенного решения  $y^*$  введены абсолютные и относительные погрешности  $\Delta(x^*)$ ,  $\Delta(y^*)$ ,  $\delta(x^*)$ ,  $\delta(y^*)$ , а также их границы  $\bar{\Delta}(x^*)$ ,  $\bar{\Delta}(y^*)$ ,  $\bar{\delta}(x^*)$ ,  $\bar{\delta}(y^*)$ . Определения этих величин в случае, когда  $x$  и  $y$  — числа, были даны в § 2.2. В тех случаях, когда входные данные или решение не являются числами, эти характеристики погрешностей также можно ввести естественным образом; мы будем это делать по мере необходимости.

**2. Определение корректности задачи.** Анализ важнейших требований, предъявляемых к различным прикладным задачам, приводит к понятию корректности математической задачи, которое было впервые сформулировано Ж.Адамаром<sup>1</sup> и развито затем И.Г.Петров-

---

<sup>1</sup> Жак Адамар (1865 — 1963) — французский математик.



ским<sup>1</sup>. Вычислительная задача называется *корректной* (по Адамару — Петровскому), если выполнены следующие три требования: 1) ее решение  $y \in Y$  существует при любых входных данных  $x \in X$ ; 2) это решение единственно; 3) решение устойчиво по отношению к малым возмущениям входных данных. В том случае, когда хотя бы одно из этих требований не выполнено, задача называется *некорректной*.

Существование решения вычислительной задачи — естественное требование к ней. Отсутствие решения может свидетельствовать, например, о непригодности принятой математической модели либо о неправильной постановке задачи. Иногда отсутствие решения является следствием неправильного выбора множества допустимых входных данных  $X$  или множества возможных решений  $Y$ .

**Пример 3.1.** Рассмотрим задачу о решении квадратного уравнения

$$x^2 + bx + c = 0. \quad (3.1)$$

Старший коэффициент  $a$  считается равным единице; этого всегда можно добиться делением уравнения на  $a$ . Если считать входным данным пару коэффициентов  $b, c$  и искать решение в множестве вещественных чисел, то существование решений

$$x_1 = (-b - \sqrt{b^2 - 4c})/2, \quad x_2 = (-b + \sqrt{b^2 - 4c})/2 \quad (3.2)$$

будет гарантировано только в том случае, если ограничить множество входных данных коэффициентами, удовлетворяющими условию  $b^2 - 4c \geq 0$ . Если же расширить множество возможных решений и считать, что корни (3.2) могут принимать комплексные значения, то задача будет иметь решение при любых  $b, c$ .

Так как математическая модель не является абсолютно точным отражением реальной ситуации, то даже в случае, когда исходная проблема заведомо имеет решение, соответствующая вычислительная задача может и не оказаться разрешимой. Конечно, такая ситуация говорит о серьезном дефекте в постановке задачи. В некоторых случаях отсутствие решения математической задачи приводит к пониманию

---

<sup>1</sup> Иван Георгиевич Петровский (1901 — 1973) — российский математик.

того, что первоначально сформулированная проблема неразрешима и нуждается в серьезной корректировке.

**3. Единственность.** Для некоторых вычислительных задач единственность является естественным свойством; для других же решение может и не быть единственным. Например, квадратное уравнение (3.1) имеет два корня (3.2). Как правило, если задача имеет реальное содержание, то неединственность может быть ликвидирована введением дополнительных ограничений на решение (т.е. сужением множества  $Y$ ). В некоторых случаях проблема снимается тем, что признается целесообразным найти набор всех решений, отвечающих входным данным  $x$ , и тогда за решение  $y$  принимается этот набор. Например, для уравнения (3.1) решением можно назвать пару  $(x_1, x_2)$ .

Неединственность решения вычислительной задачи — весьма неприятное свойство. Оно может быть проявлением неправильной постановки исходной прикладной проблемы, неоднозначности ее решения или сигналом о неудачном выборе математической модели.

**4. Устойчивость решения.** Решение  $y$  вычислительной задачи называется *устойчивым по входным данным  $x$* , если оно зависит от входных данных непрерывным образом. Это означает, что для любого  $\varepsilon > 0$  существует  $\delta = \delta(\varepsilon) > 0$  такое, что всякому исходному данному  $x^*$ , удовлетворяющему условию  $\Delta(x^*) < \delta$ , отвечает приближенное решение  $y^*$ , для которого  $\Delta(y^*) < \varepsilon$ . Таким образом, для устойчивой вычислительной задачи ее решение теоретически можно найти со сколь угодно высокой точностью  $\varepsilon$ , если обеспечена достаточно высокая точность  $\delta$  входных данных. Схематически ситуация изображена на рис. 3.1. Множества тех  $x^*$  и  $y^*$ , для которых  $\Delta(x^*) < \delta$  и  $\Delta(y^*) < \varepsilon$ , изображены как окрестности точек  $x$  и  $y$ , имеющие радиусы  $\delta$  и  $\varepsilon$ . Требование увеличить точность решения приводит автоматически к повышению требований к точности данных; соответствующие окрестности на рис. 3.1 отмечены пунктиром.

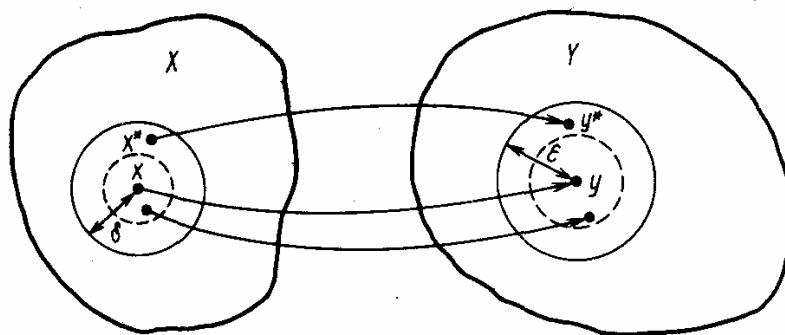


Рис. 3.1

Неустойчивость решения  $y$  означает, что существует такое  $\epsilon_0 > 0$ , что какое бы малое  $\delta > 0$  ни было задано, найдутся такие исходные данные  $x^*$ , что  $\Delta(x^*) < \delta$ , но  $\Delta(y^*) \geq \epsilon_0$ .

Приведем простейшие примеры устойчивых и неустойчивых задач.

**Пример 3.2.** Задача вычисления корней квадратного уравнения (3.1) устойчива, так как корни (3.2) являются непрерывными функциями коэффициентов  $b$  и  $c$ .

**Пример 3.3.** Задача о вычислении ранга матрицы в общем случае неустойчива. В самом деле, для матрицы  $A = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$  ранг равен 1, поскольку  $\det A = 0$  и существует ненулевой элемент  $a_{11} = 1$ . Однако сколь угодно малое возмущение коэффициента  $a_{22}$  на величину  $\epsilon \neq 0$  приводит к матрице  $A_\epsilon = \begin{bmatrix} 1 & 0 \\ 0 & \epsilon \end{bmatrix}$ , для которой  $\det A_\epsilon = \epsilon \neq 0$  и, следовательно, ранг равен 2.

**Пример 3.4.** Покажем, что задача вычисления определенного интеграла  $I = \int_a^b f(x) dx$  устойчива.

Пусть  $f^*(x)$  — приближенно заданная интегрируемая функция и  $I^* = \int_a^b f^*(x) dx$ . Определим абсолютную погрешность функции  $f^*$  с помощью равенства  $\Delta(f^*) = \sup_{x \in [a, b]} |f(x) - f^*(x)|$ , в котором знак  $\sup$  можно заменить на  $\max$ , если  $f$  и  $f^*$  непрерывны. Так как

$$\Delta(I^*) = |I - I^*| = \left| \int_a^b (f(x) - f^*(x)) dx \right| \leq (b - a) \Delta(f^*), \quad (3.3)$$

то для любого  $\epsilon > 0$  неравенство  $\Delta(I^*) < \epsilon$  будет выполнено, если потребовать выполнения условия  $\Delta(f^*) < \delta = \epsilon / (b - a)$ .

**Пример 3.5.** Покажем, что задача вычисления производной  $u(x) = f'(x)$  приближенно заданной функции является неустойчивой.

Пусть  $f^*(x)$  — приближенно заданная на отрезке  $[a, b]$  непрерывно дифференцируемая функция и  $u^*(x) = (f^*)'(x)$ . Определим абсолютные погрешности с помощью равенств  $\Delta(f^*) = \max_{[a, b]} |f(x) - f^*(x)|$ ,  $\Delta(u^*) = \max_{[a, b]} |u(x) - u^*(x)|$ .

Возьмем, например  $f^*(x) = f(x) + \alpha \sin(x/\alpha^2)$ , где  $0 < \alpha \ll 1$ . Тогда  $u^*(x) = u(x) + \alpha^{-1} \cos(x/\alpha^2)$  и  $\Delta(u^*) = \alpha^{-1}$ , в то время как  $\Delta(f^*) = \alpha$ . Таким образом, сколь угодно малой погрешности задания функции  $f$  может отвечать сколь угодно большая погрешность производной  $f'$ .

Различие в ситуациях, возникающих при приближенном задании функции  $f$  в задачах интегрирования и дифференцирования, отражено на рис. 3.2. Видно, что уменьшение величины  $\delta = \Delta(f^*)$  влечет за собой уменьшение  $\Delta(I^*)$  (эта величина не превышает заштрихованной площади), в то время как производные  $f'$  и  $(f^*)'$  могут отличаться сколь угодно сильно.

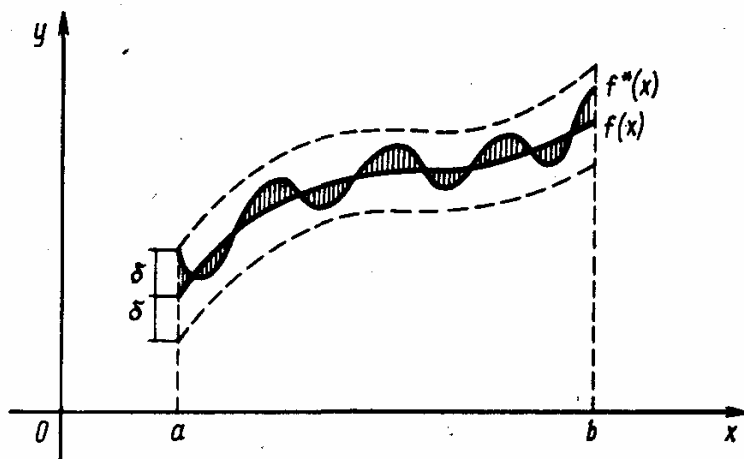


Рис. 3.2

Одна и та же задача может оказаться как устойчивой, так и неустойчивой в зависимости от выбора способа вычисления абсолютных погрешностей  $\Delta(x^*)$  и  $\Delta(y^*)$ . В реальных задачах этот выбор определяется тем, в каком смысле должно быть близко приближенное решение к точному и малость какой из мер погрешности входных данных можно гарантировать.

**Пример 3.6.** Рассмотрим задачу о вычислении суммы сходящегося ряда  $S = \sum_{k=0}^{\infty} a_k$  с приближенно заданными слагаемыми  $a_k^* \approx a_k$ . Если  $a_k^*$  определяется таким образом, что гарантируется малость  $\Delta(a_k^*)$  для всех  $k$ , то для последовательности  $a^* = \{a_k^*\}_{k=0}^{\infty}$  естественно положить  $\Delta(a^*) = \sup_{k \geq 0} |a_k - a_k^*|$ . В

такой постановке задача неустойчива. Чтобы убедиться в этом, достаточно положить  $a_k^* = a_k + \delta$  (где  $\delta > 0$ ) для  $k < N$  и  $a_k^* = a_k$  для  $k \geq N$ . Тогда для

суммы ряда  $S^* = \sum_{k=0}^{\infty} a_k^*$  имеем  $\Delta(S^*) = N\delta$ . Следовательно, как бы ни была мала величина  $\Delta(a^*) = \delta$ , абсолютную погрешность суммы ряда  $S^*$  с помощью выбора  $N$  можно сделать сколь угодно большой. Если же положить

$a_k^* = a_k + \delta$  для всех  $k$ , то сумма ряда  $S^*$  вообще станет бесконечной, т.е. ряд станет расходящимся.

В то же время, если можно задавать  $a_k^*$  так, чтобы оказалась малой величина  $\Delta(a^*) = \sum_{k=0}^{\infty} |a_k - a_k^*|$ , то  $\Delta(S^*) = \left| \sum_{k=0}^{\infty} (a_k - a_k^*) \right| \leq \Delta(a^*)$  и в такой постановке задача устойчива.

**5. Относительная устойчивость решения.** Часто требование малости абсолютной погрешности является неоправданным или трудно проверяемым. В таких случаях полезно рассмотреть *относительную устойчивость* решения, определение которой отличается от данного выше определения устойчивости (*абсолютной устойчивости*) только тем, что  $\Delta(x^*)$  и  $\Delta(y^*)$  заменяются на  $\delta(x^*)$  и  $\delta(y^*)$  соответственно.

**Пример 3.7.** Вернемся к задаче вычисления суммы ряда  $S = \sum_{k=0}^{\infty} a_k$  из примера 3.6. Предположим, что  $a_k \neq 0$  для всех  $k$ . Часто можно гарантировать малость величины  $\delta(a^*) = \sup_{k \geq 0} \{ |a_k - a_k^*| / |a_k| \}$ . Тогда  $\Delta(a_k^*) \leq |a_k| \cdot \delta(a^*)$  и

поэтому  $\Delta(S^*) \leq \sum_{k=0}^{\infty} |a_k| \cdot \delta(a^*)$ . Таким образом,

$$\delta(S^*) \leq \left[ \sum_{k=0}^{\infty} |a_k| / \left| \sum_{k=0}^{\infty} a_k \right| \right] \delta(a^*). \quad (3.4)$$

Следовательно, задача вычисления суммы сходящегося ряда  $S$  относительно устойчива, если он сходится абсолютно (т.е. сходится ряд  $\sum_{k=0}^{\infty} |a_k|$ ). Если же ряд сходится только условно, т.е.  $\sum_{k=0}^{\infty} |a_k| = \infty$ , то задача не является относительно устойчивой.

**З а м е ч а н и е.** Так как для решения вычислительных задач используют ЭВМ, точность которых определяется разрядностью мантииссы или эквивалентной величиной границы относительной погрешности округления  $\epsilon_m$ , то представляется более естественным исследование относительной устойчивости.

**6. О некорректных задачах.** Длительное время считалось, что некорректные задачи, решения которых неустойчивы, не имеют физического смысла и не представляют ценности для приложений. Однако это мнение оказалось ошибочным. Как выяснилось, многие важные прикладные задачи некорректны. Не вызывает, например, сомнения

практическая важность решения некорректных задач дифференцирования и суммирования ряда (см. примеры 3.5, 3.6). К некорректным задачам относятся также обратные задачи геофизики, астрофизики, спектрографии, многие задачи распознавания образов, задачи синтеза и ряд других прикладных задач.

К настоящему времени разработана теория решения многих классов некорректных задач. Важная роль в создании методов решения таких задач принадлежит российским математикам, в первую очередь А.Н.Тихонову<sup>1</sup>. Эти методы (*методы регуляризации*) довольно сложны и выходят за рамки данной книги. Для первого знакомства с ними можно рекомендовать учебное пособие [79].

### § 3.2. Обусловленность вычислительной задачи

**1. Определения.** Пусть вычислительная задача корректна (ее решение существует, единственно и устойчиво по входным данным). Теоретически наличие у задачи устойчивости означает, что ее решение может быть найдено со сколь угодно малой погрешностью, если только гарантировать, что погрешности входных данных достаточно малы. Однако на практике погрешности входных данных не могут быть сделаны сколь угодно малыми, точность их ограничена. Даже то, что исходные данные нужно будет ввести в ЭВМ, означает, что их относительная точность будет заведомо ограничена величиной порядка  $\epsilon_m$  (см. § 2.5). В реальности, конечно, уровень ошибок в исходной информации будет существенно выше. Как же повлияют малые, но конечные погрешности входных данных на решение, как сильно способны они исказить желаемый результат? Для ответа на этот вопрос введем новые понятия.

Под *обусловленностью вычислительной задачи* понимают чувствительность ее решения к малым погрешностям входных данных. Задачу называют *хорошо обусловленной*, если малым погрешностям входных данных отвечают малые погрешности решения, и *плохо обусловленной*, если возможны сильные изменения решения.

Часто оказывается возможным ввести количественную меру степени обусловленности вычислительной задачи — *число обусловленности*. Эту величину можно интерпретировать как коэффициент возможного возрастания погрешностей в решении по отношению к вызвавшим их погрешностям входных данных.

---

<sup>1</sup> Андрей Николаевич Тихонов (1906—1993) — российский математик.

Пусть между абсолютными погрешностями входных данных  $x$  и решения  $y$  установлено неравенство

$$\Delta(y^*) \leq \nu_{\Delta} \Delta(x^*). \quad (3.5)$$

Тогда величина  $\nu_{\Delta}$  называется *абсолютным числом обусловленности*.

Если же установлено неравенство

$$\delta(y^*) \leq \nu_{\delta} \delta(x^*) \quad (3.6)$$

между относительными ошибками данных и решения, то величину  $\nu_{\delta}$  называют *относительным числом обусловленности*. В неравенствах (3.5), (3.6) вместо погрешностей  $\Delta$  и  $\delta$  могут фигурировать их границы  $\bar{\Delta}$  и  $\bar{\delta}$ . Обычно под числом обусловленности  $\nu$  задачи понимают одну из величин  $\nu_{\Delta}$  или  $\nu_{\delta}$ , причем выбор бывает ясен из смысла задачи.

Чаще все же под числом обусловленности понимают относительное число обусловленности. Для плохо обусловленной задачи  $\nu \gg 1$ . В некотором смысле неустойчивость задачи — это крайнее проявление плохой обусловленности, отвечающее значению  $\nu = \infty$ . Конечно,  $\nu$  — это максимальный коэффициент возможного возрастания уровня ошибок, и для конкретных исходных данных действительный коэффициент возрастания может оказаться существенно меньше. Однако при выводе оценок (3.5) и (3.6) стремятся к тому, чтобы не завышать значений  $\nu_{\Delta}$  и  $\nu_{\delta}$  и поэтому соотношение  $\nu \gg 1$  все же свидетельствует о реальной возможности существенного роста ошибок. Грубо говоря, если  $\nu \sim 10^N$ , где  $\nu$  — относительное число обусловленности, то порядок  $N$  показывает число верных цифр, которое может быть утеряно в результате по сравнению с числом верных цифр входных данных.

Каково то значение  $\nu$ , при котором следует признать задачу плохо обусловленной? Ответ на этот вопрос существенно зависит, с одной стороны, от предъявляемых требований к точности решения и, с другой — от уровня обеспечиваемой точности исходных данных. Например, если требуется найти решение с точностью 0.1%, а входная информация задается с точностью 0.02%, то уже значение  $\nu = 10$  сигнализирует о плохой обусловленности. Однако (при тех же требованиях к точности результата) гарантия, что исходные данные задаются с точностью не ниже 0.0001%, означает, что и при  $\nu = 10^3$  задача хорошо обусловлена.

С простым, но очень важным примером плохо обусловленной задачи мы уже познакомились в § 2.3. Это задача вычитания приближенных чисел одного знака. Оценка (2.10) дает для нее значение относи-

тельного числа обусловленности  $\nu = |a + b|/|a - b|$ . Так как в примере 2.11 имеем  $\nu \approx |1 + x^*|/|1 - x^*| \approx 7 \cdot 10^5$ , то потеря пяти верных значащих цифр здесь не представляется удивительной.

**2. Примеры плохо обусловленных задач.** Первым рассмотрим классический пример, принадлежащий Дж. Уилкинсону [83].

**Пример 3.8.** Пусть требуется найти корни многочлена

$$P(x) = (x-1)(x-2) \dots (x-20) = x^{20} - 210x^{19} + \dots$$

по заданным значениям его коэффициентов. Из теории известно, что эта задача устойчива. Возьмем коэффициент  $\alpha = -210$  при  $x^{19}$  и изменим его значение на  $\alpha^* = -210 + 2^{-23}$ . Как повлияет эта, казалось бы, незначительная ошибка на значения корней? Заметим, что  $x_1 = 1, x_2 = 2, \dots, x_{20} = 20$  — точные значения корней.

Вычисленные с высокой точностью корни возмущенного многочлена таковы:

$$\begin{aligned} x_1^* &\approx 1.00000; x_2^* \approx 2.00000; x_3^* \approx 3.00000; x_4^* \approx 4.00000; x_5^* \approx 5.00000; \\ x_6^* &\approx 6.00001; x_7^* \approx 6.99970; x_8^* \approx 8.00727; x_9^* \approx 8.91725; \\ x_{10,11}^* &\approx 10.0953 \pm 0.643501i; x_{12,13}^* \approx 11.7936 \pm 1.65233i; \\ x_{14,15}^* &\approx 13.9924 \pm 2.51883i; x_{16,17}^* \approx 16.7307 \pm 2.81262i; \\ x_{18,19}^* &\approx 19.5024 \pm 1.94033i; x_{20}^* \approx 20.8469. \end{aligned}$$

Как нетрудно видеть, корни  $x_1, \dots, x_6$  оказались практически нечувствительны к погрешностям в коэффициенте  $\alpha$ . В то же время некоторые корни превратились в комплексные и имеют относительные погрешности от 6 до 18%, несмотря на то, что  $\delta(\alpha^*) \approx 6 \cdot 10^{-8}\%$ .

В данном случае нетрудно провести анализ чувствительности корней. Пусть  $F(x, \alpha) = x^{20} + \alpha x^{19} + \dots$ . Будем рассматривать корни  $x_k$  как функции параметра  $\alpha$ , т.е.  $x_k = x_k(\alpha)$ . Равенство  $F(x_k(\alpha), \alpha) = 0$ , выполненное в окрестности  $\alpha = -210$ , задает  $x_k$  как неявную функцию от  $\alpha$ . Пользуясь второй из формул (2.22) для границы относительной погрешности и применяя формулу (2.23) для производной неявной функции, имеем  $\bar{\delta}(x_k^*) \approx \nu_k \bar{\delta}(\alpha^*)$ , где

$$\begin{aligned} \nu_k &= \frac{|\alpha| \cdot |F'_\alpha / F'_x|}{|x|} \bigg|_{\substack{x=x_k \\ \alpha=-210}}. \text{ Учитывая, что } \frac{\partial F}{\partial \alpha} = x^{19} \text{ и } \frac{\partial F}{\partial x} \bigg|_{\alpha=-210} = P'(x) = \\ &= \sum_{j=1}^{20} \prod_{i \neq j} (x - i), \text{ получаем } \nu_k = \frac{210 \kappa^{18}}{\prod_{i \neq k} |k - i|}. \end{aligned}$$



Вычисление чисел  $\nu_k$  дает следующие значения:

$$\begin{aligned} \nu_1 &\approx 2 \cdot 10^{-15}, \nu_2 \approx 9 \cdot 10^{-8}, \nu_3 \approx 10^{-4}, \nu_4 \approx 10^{-1}, \nu_5 \approx 3 \cdot 10^1, \\ \nu_6 &\approx 2 \cdot 10^3, \nu_7 \approx 8 \cdot 10^4, \nu_8 \approx 2 \cdot 10^6, \nu_9 \approx 2 \cdot 10^7, \nu_{10} \approx 2 \cdot 10^8, \\ \nu_{11} &\approx 9 \cdot 10^9, \nu_{12} \approx 4 \cdot 10^9, \nu_{13} \approx 10^{10}, \nu_{14} \approx 2 \cdot 10^{10}, \nu_{15} \approx 3 \cdot 10^{10}, \\ \nu_{16} &\approx 3 \cdot 10^{10}, \nu_{17} \approx 3 \cdot 10^{10}, \nu_{18} \approx 10^{10}, \nu_{19} \approx 3 \cdot 10^9, \nu_{20} \approx 5 \cdot 10^8, \end{aligned}$$

свидетельствующие о чрезвычайно плохой обусловленности старших корней.

Следует обратить серьезное внимание на то, что задача вычисления корней многочленов высокой степени часто оказывается плохо обусловленной. Поэтому имеет смысл с определенной осторожностью относиться к алгоритмам, составной частью которых является вычисление корней многочленов высокой степени.

К сожалению, эта задача может быть плохо обусловленной и для многочленов невысокой степени, в особенности, если вычисляются кратные корни.

**Пример 3.9.** Пусть ищется решение уравнения  $(x - 1)^4 = 0$  с кратным корнем. Ошибка в младшем коэффициенте, равная  $10^{-8}$ , приводит к уравнению  $(x - 1)^4 = 10^{-8}$ , имеющему следующие корни:  $x_{1,2} = 1 \pm 10^{-2}$ ,  $x_{3,4} = 1 \pm 10^{-2} \cdot i$ . В этом случае ошибка в  $10^{-6}\%$  в одном из коэффициентов привела к погрешности решения в 1%, что явно говорит о плохой обусловленности задачи.

**3. Обусловленность задачи вычисления значения функции одной переменной.** Пусть задача состоит в вычислении по заданному  $x$  значения  $y = f(x)$  дифференцируемой функции  $f$ . В силу формул (2.21), (2.22) для этой задачи имеем

$$\nu_\Delta \approx |f'(x)|, \quad (3.7)$$

$$\nu_\delta \approx \frac{|x| \cdot |f'(x)|}{|f(x)|}. \quad (3.8)$$

Воспользуемся этими формулами для оценки обусловленности задачи вычисления значений некоторых простейших функций.

**Пример 3.10.** Для задачи вычисления значения функции  $y = e^x$  в силу формулы (3.8) относительное число обусловленности  $\nu_\delta$  приближенно равно  $|x|$  и при реальных вычислениях эта величина не может быть очень большой. Например, при вычислении экспоненты на компьютере типа IBM PC всегда  $|x| < 88$ , так как в противном случае возможно переполнение или антипереполнение. Следовательно, задача вычисления этой функции хорошо обусловлена, однако в случае  $10 < |x| < 10^2$  следует ожидать потери 1–2

верных значащих цифр по сравнению с числом верных цифр аргумента  $x$ . Подчеркнем, что эта потеря точности объективно обусловлена погрешностью задания аргумента и не связана с используемым алгоритмом.

**Пример 3.11.** Для задачи вычисления значения функции  $y = \sin x$  в силу формулы (3.7) имеем  $\nu_\Delta = |\cos x| \leq 1$ , что гово-

рит о хорошей абсолютной обусловленности этой задачи при всех  $x$ . Однако если важен результат с определенным числом верных знаков, то нужно исследовать относительную обусловленность. Согласно формуле (3.8) имеем  $\nu_\delta = |x \operatorname{ctg} x|$ . На рис. 3.3 приве-

ден график этой функции при  $x \geq 0$  (она четная).

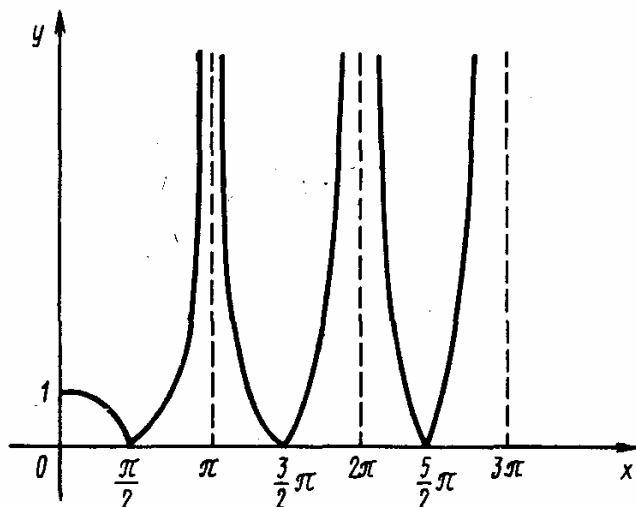


Рис. 3.3

Так как  $\nu_\delta \rightarrow \infty$  при  $x \rightarrow \pi k$  (для  $k = \pm 1, \pm 2, \dots$ ), то при  $x \approx \pi k$  задача обладает плохой относительной обусловленностью, и можно лишь утешаться тем, что мала абсолютная погрешность значения  $y^* = \sin x^*$ . Если же значение  $|x|$  очень велико, то  $\nu_\delta \gg 1$  и вычислять значение синуса просто бессмысленно. Например, если вычисления ведутся на компьютере типа IBM PC, где  $\epsilon_M \sim 10^{-7}$ , то уже для  $|x| \sim 10^7$  одна только абсолютная ошибка представления числа  $x$  есть величина порядка единицы, так как  $\Delta(x^*) \approx |x| \cdot \epsilon_M$ . Нетрудно понять, что при  $\Delta(x^*) \sim 1$  вычисленное любым способом значение  $\sin x^*$  не представляет никакой ценности. Вывод, который можно сделать, довольно прост: при использовании функции  $y = \sin x$  желательно проводить вычисления так, чтобы аргумент находился в диапазоне  $|x| \leq 2$ , поскольку здесь  $\nu_\delta \leq 1$ .

**4. Обусловленность задачи вычисления интеграла**  $I = \int_a^b f(x) dx$ . Как следует из оценки (3.3), в этом случае абсолютное число обусловленности имеет вид  $\nu_\Delta = (b - a)$ . Если же перейти к рассмотрению относительных погрешностей и положить  $\delta(f^*) = \sup_{[a, b]} |f^*(x) - f(x)| / |f(x)|$  для тех  $x$ , где  $f(x) \neq 0$ , то используя неравенство

$$\Delta(I^*) \leq \int_a^b |f^*(x) - f(x)| dx \leq \int_a^b |f(x)| dx \cdot \delta(f^*),$$

получим оценку

$$\delta(I^*) \leq \nu_\delta \delta(f^*), \quad (3.9)$$

в которой  $\nu_\delta = \frac{\int_a^b |f(x)| dx}{\int_a^b f(x) dx}$ .

Если подынтегральная функция знакопостоянна, то  $\nu_\delta = 1$  и задача хорошо обусловлена. Если же функция  $f$  на  $[a, b]$  принимает значения разных знаков, то  $\nu_\delta > 1$ . Для некоторых сильно колеблющихся (осциллирующих) около нуля функций может оказаться, что  $\nu_\delta \gg 1$  и тогда задача вычисления интеграла является плохо обусловленной.

Иногда причиной появления плохо обусловленных задач становится отсутствие у пользователя ЭВМ элементарного представления об их существовании. В связи с этим заметим, что в последнее время получает развитие опасная тенденция пренебрежительного отношения к математическим знаниям вообще и к знанию вычислительной математики, в частности. Вера в могущество ЭВМ и надежность стандартных программ бывает так велика, что считается совсем ненужным знать о вычисляемой математической величине что-либо кроме ее определения и, возможно, геометрического или физического смысла. Приведем простой пример, иллюстрирующий оценку (3.9) и заодно показывающий, что иногда аналитическая выкладка бывает эффективнее, чем применение самого современного компьютера.

**Пример 3.12.** Пусть в распоряжении пользователя имеется высокопроизводительная ЭВМ и стандартная программа для вычисления интегралов вида  $I = \int_a^b f(x) dx$ . Предположим, что нужно вычислить коэффициенты Фурье  $g_n = \int_{-1}^1 g(x) \sin \pi n x dx$  для функции  $g(x) = x + A e^{\cos^2 x}$  при  $n \gg 1$  и  $A \gg 1$ . Использование для вычисления  $g_n$  указанной стандартной программы при  $f(x) = g(x) \sin \pi n x$  автоматически означает, что ставится вычислительная задача, рассмотренная выше. При этом величина относительной погрешности  $\delta(f^*)$  вычисляемой на ЭВМ функции  $f^* \approx f$  заведомо не может быть меньше<sup>1</sup>  $\epsilon_m$ .

Оценим величину  $\nu_\delta$ . Заметим, что функция  $A e^{\cos^2 x} \sin \pi n x$  нечетная и,

---

<sup>1</sup> Если учитывать погрешность вычисления функции  $\sin \pi n x$ , то следует ожидать, что эта величина будет значительно больше  $\epsilon_m$ .

следовательно, интеграл от нее равен нулю. Поэтому возможно аналитическое вычисление интеграла:

$$g_n = \int_{-1}^1 x \sin \pi n x \, dx = -\frac{x}{\pi n} \cos \pi n x \Big|_{-1}^1 + \frac{1}{\pi n} \int_{-1}^1 \cos \pi n x \, dx = \frac{2}{\pi n} (-1)^{n+1}.$$

Кроме того,  $|g(x)| \geq |A \cos^2 x| - |x| \geq A - 1$  и поэтому

$$\int_{-1}^1 |f(x)| \, dx = \int_{-1}^1 |g(x)| \cdot |\sin \pi n x| \, dx \geq (A - 1) \int_{-1}^1 |\sin \pi n x| \, dx = A - 1.$$

Таким образом,  $\nu_\delta \geq (A - 1)\pi n/2 \approx 1.5 \, An$ . Если  $g_n$  вычисляется, например, при  $A = 10^4$  и  $n = 10^2$ , то  $\nu_\delta \gtrsim 1.5 \cdot 10^6$ . Следовательно, для этих значений параметров принятое решение о вычислении интеграла по простейшей стандартной программе может обойтись в потерю примерно 6 значащих цифр результата. Если вычисления ведутся на ЭВМ, имеющей лишь порядка 7 десятичных значащих цифр, то возможна катастрофическая потеря точности. Заметим, что в этих рассуждениях никак не учтены погрешность реализованного в программе метода и вычислительная погрешность, наличие которых усугубляет ситуацию.

**5. Обусловленность задачи вычисления суммы ряда.** Рассмотрим задачу вычисления суммы абсолютно сходящегося ряда с ненулевыми слагаемыми. В силу оценки (3.4) эта задача устойчива, а за относительное число обусловленности следует принять величину

$$\nu_\delta = \sum_{k=0}^{\infty} |a_k| / \left| \sum_{k=0}^{\infty} a_k \right|. \quad (3.10)$$

Заметим, что для ряда с положительными слагаемыми имеем  $\nu_\delta = 1$ , т.е. задача хорошо обусловлена. Если же ряд знакопостоянный, то  $\nu_\delta > 1$  и при  $\nu_\delta \gg 1$  задача оказывается плохо обусловленной.

### § 3.3. Вычислительные методы

Обсудив некоторые важные особенности вычислительных задач, обратим внимание на те методы, которые используются в вычислительной математике для преобразования задач к виду, удобному для реализации на ЭВМ, и позволяют конструировать вычислительные алгоритмы. Мы будем называть эти методы *вычислительными*. С некоторой степенью условности можно разбить вычислительные методы на следующие классы: 1) методы эквивалентных преобразований; 2) мето-

ды аппроксимации; 3) прямые (точные) методы; 4) итерационные методы; 5) методы статистических испытаний (методы Монте—Карло). Метод, осуществляющий вычисление решения конкретной задачи, может иметь довольно сложную структуру, но его элементарными шагами, являются, как правило, реализации указанных методов. Дадим о них общее представление.

**1. Методы эквивалентных преобразований.** Эти методы позволяют заменить исходную задачу другой, имеющей то же решение. Выполнение эквивалентных преобразований оказывается полезным, если новая задача проще исходной или обладает лучшими свойствами, или для нее существует известный метод решения, а, может быть, и готовая программа.

**Пример 3.13.** Эквивалентное преобразование квадратного уравнения  $x^2 + bx + c = 0$  к виду  $\left[x + \frac{b}{2}\right]^2 = \frac{b^2 - 4c}{4}$  (выделение полного квадрата) сводит задачу к проблеме вычисления квадратного корня и приводит к известным для ее корней формулам (3.2).

Эквивалентные преобразования иногда позволяют свести решение исходной вычислительной задачи к решению вычислительной задачи совершенно иного типа.

**Пример 3.14.** Задача отыскания корня нелинейного уравнения  $f(x) = 0$  может быть сведена к эквивалентной задаче поиска точки глобального минимума функции  $\Phi(x) = (f(x))^2$ . В самом деле, функция  $\Phi(x)$  неотрицательна и достигает минимального значения, равного нулю, при тех и только тех  $x$ , для которых  $f(x) = 0$ .

**2. Методы аппроксимации.** Эти методы позволяют приблизить (аппроксимировать) исходную задачу другой, решение которой в определенном смысле близко к решению исходной задачи. Погрешность, возникающая при такой замене, называется *погрешностью аппроксимации*. Как правило, аппроксимирующая задача содержит некоторые параметры, позволяющие регулировать величину погрешности аппроксимации или воздействовать на другие свойства задачи. Принято говорить, что метод аппроксимации *сходится*, если погрешность аппроксимации стремится к нулю при стремлении параметров метода к некоторому предельному значению.

**Пример 3.15.** Один из простейших способов вычисления интеграла  $I = \int_a^b f(x)dx$  состоит в аппроксимации интеграла на основании формулы прямоугольников величиной

$$I^h = h \sum_{i=1}^n f(a + (i - \frac{1}{2})h).$$

Шаг  $h = (b - a)/n$  является здесь параметром метода. Так как  $I^h$  представляет собой специальным образом построенную интегральную сумму, то из определения определенного интеграла следует, что при  $h \rightarrow 0$  метод прямоугольников сходится, т.е.  $I^h \rightarrow I$ .

**Пример 3.16.** Учитывая определение производной функции  $f'(x) = \lim_{h \rightarrow 0} \frac{f(x + h) - f(x)}{h}$ , для ее приближенного вычисления можно использовать формулу  $f'(x) \approx \frac{f(x + h) - f(x)}{h}$ . Погрешность аппроксимации этой формулы численного дифференцирования стремится к нулю при  $h \rightarrow 0$ .

Одним из распространенных методов аппроксимации является *дискретизация* — приближенная замена исходной задачи *конечномерной задачей*, т.е. задачей, входные данные и искомое решение которой могут быть однозначно заданы конечным набором чисел. Для задач, которые не являются конечномерными, этот шаг необходим для последующей реализации на ЭВМ, так как вычислительная машина в состоянии оперировать лишь с конечным количеством чисел. В приведенных выше примерах 3.15 и 3.16 была использована дискретизация. Хотя точное вычисление интеграла и предполагает использование бесконечного числа значений  $f(x)$  (для всех  $x \in [a, b]$ ), его приближенное значение можно вычислить, используя конечное число  $n$  значений в точках  $a + (i - 1/2)h$ . Аналогично, задача вычисления производной, точное решение которой предполагает выполнение операции предельного перехода при  $h \rightarrow 0$  (а следовательно, использование бесконечного числа значений функции  $f$ ), сводится к приближенному вычислению производной по двум значениям функции.

При решении нелинейных задач широко используют различные *методы линеаризации*, состоящие в приближенной замене исходной задачи более простыми линейными задачами.

**Пример 3.17.** Пусть требуется приближенно вычислить значение  $x = \sqrt{a}$  для  $a > 0$  на ЭВМ, способной выполнять простейшие арифметические операции. Заметим, что по определению  $x$  является положительным корнем нелинейного уравнения  $x^2 - a = 0$ . Пусть  $x^{(0)}$  — некоторое известное приближение к  $\sqrt{a}$ . Заменим параболу  $y = x^2 - a$  прямой  $y = (x^{(0)})^2 - a + 2x^{(0)}(x - x^{(0)})$ , являющейся касательной, проведенной к ней в

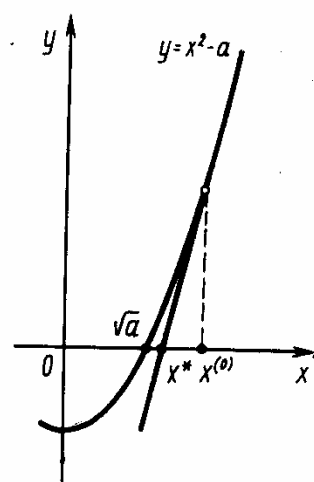


Рис. 3.4

точке с абсциссой  $x = x^{(0)}$  (рис. 3.4). Точка пересечения этой касательной с осью  $Ox$  дает лучшее, чем  $x^{(0)}$ , приближение и находится из линейного уравнения  $(x^{(0)})^2 - a + 2x^{(0)}(x - x^{(0)}) = 0$ . Решая его, получаем приближенную формулу

$$\sqrt{a} \approx x^* = x^{(0)} - \frac{(x^{(0)})^2 - a}{2x^{(0)}} = \frac{1}{2} \left( x^{(0)} + \frac{a}{x^{(0)}} \right). \quad (3.11)$$

Например, если для  $x = \sqrt{2}$  взять  $x^{(0)} = 2$ , то получится уточненное значение  $\sqrt{2} \approx x^* = \frac{1}{2} \left( 2 + \frac{2}{2} \right) = 1.5$ .

При решении разных классов вычислительных задач могут использоваться различные методы аппроксимации; к ним можно отнести и методы регуляризации решения некорректных задач. Заметим, что методы регуляризации широко используют и для решения плохо обусловленных задач.

**3. Прямые методы.** Метод решения задачи называют *прямым*, если он позволяет получить решение после выполнения конечного числа элементарных операций.

**Пример 3.18.** Метод вычисления корней квадратного уравнения  $x^2 + bx + c = 0$  по формулам  $x_{1,2} = (-b \pm \sqrt{b^2 - 4c})/2$  является прямым методом. Элементарными здесь считаются четыре арифметические операции и операция извлечения квадратного корня.

Заметим, что элементарная операция прямого метода может оказаться довольно сложной (вычисление значений элементарной или специальной функции, решение системы линейных алгебраических уравнений, вычисление определенного интеграла и т.д.). То, что она принимается за элементарную, предполагает во всяком случае, что ее выполнение существенно проще вычисления решения всей задачи.

При построении прямых методов существенное внимание уделяется минимизации числа элементарных операций.

**Пример 3.19** (с х е м а Г о р н е р а<sup>1</sup>). Пусть задача состоит в вычислении значения многочлена

$$P_n(x) = a_0 + a_1x + a_2x^2 + \dots + a_nx^n \quad (3.12)$$

---

<sup>1</sup> Вильямс Джордж Горнер (1786 — 1837) — английский математик.

по заданным коэффициентам  $a_0, a_1, \dots, a_n$  и значению аргумента  $x$ . Если вычислять многочлен непосредственно по формуле (3.12), причем  $x^2, x^3, \dots, x^n$  находить последовательным умножением на  $x$ , то потребуется выполнить  $2n - 1$  операций умножения и  $n$  операций сложения.

Значительно более экономичным является метод вычисления, называемый *схемой Горнера*. Он основан на записи многочлена в следующем эквивалентном виде:

$$P_n(x) = ((\dots ((a_n x + a_{n-1})x + a_{n-2})x + \dots)x + a_1)x + a_0.$$

Расстановка скобок диктует такой порядок вычислений:  $S_0 = a_n, S_1 = S_0 x + a_{n-1}, S_2 = S_1 x + a_{n-2}, \dots, S_i = S_{i-1} x + a_{n-i}, \dots, S_n = S_{n-1} x + a_0$ . Здесь вычисление значения  $P_n(x) = S_n$  потребовало выполнения только  $n$  операций умножения и  $n$  операций сложения.

Схема Горнера интересна тем, что дает пример оптимального по числу элементарных операций метода. В общем случае значение  $P_n(x)$  нельзя получить никаким методом в результате выполнения меньшего числа операций умножения и сложения.

Иногда прямые методы называют *точными*, подразумевая под этим, что при отсутствии ошибок во входных данных и при точном выполнении элементарных операций полученный результат также будет точным. Однако при реализации метода на ЭВМ неизбежно появление вычислительной погрешности, величина которой зависит от чувствительности метода к ошибкам округления. Многие прямые (точные) методы, разработанные в домашний период, оказались непригодными для машинных вычислений именно из-за чрезмерной чувствительности к ошибкам округления. Не все точные методы таковы, однако стоит заметить, что не совсем удачный термин "точный" характеризует свойства идеальной реализации метода, но отнюдь не качество полученного при реальных вычислениях результата.

**4. Итерационные методы.** Это — специальные методы построения последовательных приближений к решению задачи. Применение метода начинают с выбора одного или нескольких начальных приближений. Для получения каждого из последующих приближений выполняют однотипный набор действий с использованием найденных ранее приближений — *итерацию*<sup>1</sup>. Неограниченное продолжение этого *итерационного процесса* теоретически позволяет построить бесконечную последовательность приближений к решению —

---

<sup>1</sup> От лат. *iteratio* — "повторение".



*итерационную последовательность*. Если эта последовательность сходится к решению задачи, то говорят, что *итерационный метод сходится*. Множество начальных приближений, для которых метод сходится, называется *областью сходимости метода*.

Заметим, что итерационные методы широко используются при решении самых разнообразных задач с применением ЭВМ.

**Пример 3.20.** Рассмотрим известный итерационный метод, предназначенный для вычисления  $\sqrt{a}$  (где  $a > 0$ ), — *метод Ньютона*. Зададим произвольное начальное приближение  $x^{(0)} > 0$ . Следующее приближение вычислим по формуле  $x^{(1)} = \frac{1}{2} \left[ x^{(0)} + \frac{a}{x^{(0)}} \right]$ , выведенной с помощью метода линеаризации в примере 3.17 (см. формулу (3.11)). Продолжая этот процесс далее, получим итерационную последовательность  $x^{(0)}, x^{(1)}, x^{(2)}, \dots, x^{(n)}, \dots$ , в которой очередное  $(k + 1)$ -е приближение вычисляется через  $k$ -е по *рекуррентной<sup>1</sup> формуле*

$$x^{(k+1)} = \frac{1}{2} \left[ x^{(k)} + \frac{a}{x^{(k)}} \right], \quad k \geq 0. \quad (3.13)$$

Известно, что этот метод сходится при любом начальном приближении  $x^{(0)} > 0$ , так что его область сходимости — множество всех положительных чисел.

Вычислим с его помощью значение  $\sqrt{2}$  на 8-разрядной десятичной ЭВМ. Зададим  $x^{(0)} = 2$  (как в примере 3.17). Тогда  $x^{(1)} = 1.5$ ,  $x^{(2)} = 1.4166667$ ,  $x^{(3)} = 1.4142166$ ,  $x^{(4)} = 1.4142136$ ,  $x^{(5)} = 1.4142136$ . Дальнейшие вычисления бессмысленны, так как из-за ограниченности разрядной сетки все следующие уточнения будут давать тот же результат. Однако сравнение с точным значением  $\sqrt{2} = 1.41421356\dots$  показывает, что уже на третьей итерации были получены 6 верных значащих цифр.

Обсудим на примере метода Ньютона некоторые типичные для итерационных методов (и не только для них) проблемы. Итерационные методы по своей сути являются приближенными; ни одно из получаемых приближений не является точным значением решения. Однако сходящийся итерационный метод дает принципиальную возможность найти решение с любой заданной точностью  $\epsilon > 0$ . Поэтому, применяя итерационный метод, всегда задают требуемую точность  $\epsilon$  и итерационный процесс прерывают, как только она достигается.

---

<sup>1</sup> От лат. *resurgens* — "возвращающийся".

Хотя сам факт сходимости метода безусловно важен, он недостаточен для того, чтобы рекомендовать метод для использования на практике. Если метод сходится очень медленно (например, для получения решения с точностью в 1% нужно сделать  $10^6$  итераций), то он непригоден для вычислений на ЭВМ. Практическую ценность представляют быстро сходящиеся методы, к которым относится и метод Ньютона (напомним, что точность  $\varepsilon = 10^{-5}$  в вычислении  $\sqrt{2}$  была достигнута всего за три итерации). Для теоретического исследования скорости сходимости и условий применимости итерационных методов выводят так называемые *априорные*<sup>1</sup> *оценки погрешности*, позволяющие еще до вычислений дать некоторое заключение о качестве метода.

Приведем две такие априорные оценки для метода Ньютона. Пусть  $x^{(0)} > \sqrt{a}$ . Известно, что тогда  $x^{(n)} > \sqrt{a}$  для всех  $n \geq 0$  и погрешности двух последовательных приближений связаны следующим неравенством:

$$\delta^{(n)} \leq (\delta^{(n-1)})^2. \quad (3.14)$$

Здесь  $\delta^{(n)} = \frac{1}{2\sqrt{a}} (x^{(n)} - \sqrt{a}) = \frac{\delta(x^{(n)})}{2}$  — величина, характеризу-

ющая относительную погрешность  $n$ -го приближения. Это неравенство говорит об очень высокой квадратичной скорости сходимости метода: на каждой итерации "ошибка"  $\delta^{(n)}$  возводится в квадрат. Если выразить  $\delta^{(n)}$  через погрешность начального приближения, то получим неравенство

$$\delta^{(n)} \leq (\delta^{(0)})^2^n, \quad (3.15)$$

из которого видна роль хорошего выбора начального приближения. Чем меньше величина  $\delta^{(0)} = \delta(x^{(0)})/2$ , тем быстрее будет сходиться метод.

Практическая реализация итерационных методов всегда связана с необходимостью выбора *критерия окончания итерационного процесса*. Вычисления не могут продолжаться бесконечно долго и должны быть прерваны в соответствии с некоторым критерием, связанным, например, с достижением заданной точности. Использование для этой цели априорных оценок чаще всего оказывается невозможным или неэффективным. Качественно верно описывая поведение метода, такие оценки являются завышенными и дают весьма недостоверную количественную информацию. Нередко априорные оценки содержат неизвестные вели-

---

<sup>1</sup> От лат. a'priori — "до опыта".

чины (например, в оценках (3.14), (3.15) содержится величина  $\sqrt{a}$ ), либо предполагают наличие и серьезное использование некоторой дополнительной информации о решении. Чаще всего такой информации нет, а ее получение связано с необходимостью решения дополнительных задач, нередко более сложных, чем исходная.

Для формирования критерия окончания по достижении заданной точности, как правило, используют так называемые *апостериорные*<sup>1</sup> оценки погрешности — неравенства, в которых величина погрешности оценивается через известные или получаемые в ходе вычислительного процесса величины. Хотя такими оценками нельзя воспользоваться до начала вычислений, в ходе вычислительного процесса они позволяют давать конкретную количественную оценку погрешности.

Например, для метода Ньютона (3.13) справедлива следующая апостериорная оценка:

$$|x^{(n)} - \sqrt{a}| \leq |x^{(n)} - x^{(n-1)}|, \quad n \geq 1,$$

позволяющая оценивать абсолютную погрешность приближения через модуль разности двух последовательных приближений. Она дает возможность сформулировать при заданной точности  $\varepsilon > 0$  очень простой критерий окончания. Как только окажется выполненным неравенство

$$|x^{(n)} - x^{(n-1)}| < \varepsilon, \quad (3.16)$$

вычисления следует прекратить и принять  $x^{(n)}$  за приближение к  $\sqrt{a}$  с точностью  $\varepsilon$ .

**Пример 3.21.** Если значение  $\sqrt{2}$  требуется найти с точностью  $\varepsilon = 10^{-5}$ , то неравенство (3.16), как видно из приведенных в примере 3.20 вычислений, будет выполнено при  $n = 4$ . Так как  $|x^{(4)} - x^{(3)}| = 3 \cdot 10^{-6}$ , то с учетом погрешности округления можно записать результат:  $\sqrt{2} = 1.41421 \pm 0.00001$ .

**5. Методы статистических испытаний (методы Монте-Карло).** Это — численные методы, основанные на моделировании случайных величин и построении статистических оценок решений задач. Этот класс методов, как принято считать, возник в 1949 г., когда Дж. фон Нейман<sup>2</sup> и

---

<sup>1</sup> От лат. a'posteriori — "после опыта".

<sup>2</sup> Джон фон Нейман (1903 — 1957) — американский математик, физик, инженер-изобретатель. Оказал значительное влияние на развитие современной математики. Один из создателей первых ЭВМ.

С.Улам<sup>1</sup> использовали случайные числа для моделирования с помощью ЭВМ поведения нейтронов в ядерном реакторе. Эти методы могут оказаться незаменимыми при моделировании больших систем, но подробное их изложение предполагает существенное использование аппарата теории вероятностей и математической статистики и выходит за рамки данной книги.

### § 3.4. Корректность вычислительных алгоритмов

**1. Вычислительный алгоритм.** Вычислительный метод, доведенный до степени детализации, позволяющий реализовать его на ЭВМ, принимает форму вычислительного алгоритма.

Определим *вычислительный алгоритм* как точное предписание действий над входными данными, задающее вычислительный процесс, направленный на преобразование произвольных входных данных  $x$  (из множества допустимых для данного алгоритма входных данных  $X$ ) в полностью определяемый этими входными данными результат.

Реальный вычислительный алгоритм складывается из двух частей: *абстрактного вычислительного алгоритма*, формулируемого в общепринятых математических терминах, и *программы*, записанной на одном из алгоритмических языков и предназначенной для реализации алгоритма на ЭВМ. Как правило, в руководствах по методам вычислений излагаются именно абстрактные алгоритмы, но их обсуждение проводится так, чтобы выявить особенности алгоритмов, которые оказывают существенное влияние на качество программной реализации.

**2. Определение корректности алгоритма.** К вычислительным алгоритмам, предназначенным для широкого использования, предъявляется ряд весьма жестких требований. Первое из них — корректность алгоритма. Будем называть вычислительный алгоритм *корректным*, если выполнены три условия: 1) он позволяет после выполнения конечного числа элементарных для вычислительной машины операций преобразовать любое входное данное  $x \in X$  в результат  $y$ ; 2) результат  $y$  устойчив по отношению к малым возмущениям входных данных; 3) результат  $y$  обладает вычислительной устойчивостью. Если хотя бы одно из перечисленных условий не выполнено, то будем называть алгоритм *некорректным*. Уточним и более подробно обсудим эти условия.

---

<sup>1</sup> Станислав Улам (1909 — 1984) — американский математик.

Необходимость выполнения первого условия понятна. Если для получения результата нужно выполнить бесконечное число операций либо требуются операции, не реализованные на ЭВМ, то алгоритм следует признать некорректным.

**Пример 3.22.** Известный алгоритм деления чисел "углом" некорректен, так как он может продолжаться бесконечно, если не определен критерий окончания вычислений.

**Пример 3.23.** Отсутствие критерия окончания делает некорректным и алгоритм Ньютона вычисления  $\sqrt{a}$  (см. пример 3.20).

**Пример 3.24.** Алгоритм вычисления корней квадратного уравнения (3.1) по формулам (3.2) некорректен, если он предназначен для использования на вычислительной машине, на которой не реализована операция извлечения квадратного корня.

**3. Устойчивость по входным данным.** Устойчивость результата  $y$  к малым возмущениям входных данных (*устойчивость по входным данным*) означает, что результат непрерывным образом зависит от входных данных при условии, что отсутствует вычислительная погрешность. Это требование устойчивости аналогично требованию устойчивости вычислительной задачи. Отсутствие такой устойчивости делает алгоритм непригодным для использования на практике.

Отметим, что в формулировку устойчивости алгоритма по входным данным неявно входит одно весьма важное предположение, а именно, что вместе с входным данным  $x$  в множество допустимых входных данных  $X$  входят и все близкие к  $x$  приближенные входные данные  $x^*$ .

**Пример 3.25.** Пусть алгоритм предназначен для вычисления корней квадратного уравнения (3.1) с коэффициентом, удовлетворяющими условию  $d = b^2 - 4c \geq 0$ . Если в нем используются формулы (3.2), то этот алгоритм некорректен. В самом деле, значение  $d^*$ , отвечающее приближенно заданным коэффициентам  $b^*$  и  $c^*$ , может оказаться отрицательным, если  $d \approx 0$ . Тогда вычисления завершатся аварийным остановом при попытке извлечь квадратный корень из отрицательного числа. Если же в формуле (3.2) заменить  $d$  на  $\max\{d, 0\}$ , то алгоритм становится корректным.

**4. Вычислительная устойчивость.** Из-за наличия ошибок округления при вводе входных данных в ЭВМ и при выполнении арифметических операций неизбежно появление вычислительной погрешности. Ее величина на разных ЭВМ различна из-за различий в разрядности и способах округления, но для фиксированного алгоритма в основном величина погрешности определяется машинной точностью  $\epsilon_M$ .

Назовем алгоритм *вычислительно устойчивым*, если вычислительная погрешность результата стремится к нулю при  $\epsilon_m \rightarrow 0$ . Обычно вычислительный алгоритм называют *устойчивым*, если он устойчив по входным данным и вычислительно устойчив, и *неустойчивым*, если хотя бы одно из этих условий не выполнено.

**Пример 3.26<sup>1</sup>.** Пусть требуется составить таблицу значений интегралов  $I_n = \int_0^1 x^n e^{1-x} dx$  для  $n = 1, 2, \dots$  на 6-разрядной десятичной ЭВМ.

Интегрируя по частям, имеем

$$I_n = \int_0^1 x^n d(-e^{1-x}) = -x^n e^{1-x} \Big|_0^1 + \int_0^1 e^{1-x} d(x^n) = -1 + \int_0^1 n x^{n-1} e^{1-x} dx.$$

Следовательно, справедлива формула

$$I_n = n I_{n-1} - 1, \quad n \geq 1. \quad (3.17)$$

Кроме того,  $I_0 = \int_0^1 e^{1-x} dx = e - 1 \approx I_0^* = 1.71828$ .

Воспользуемся формулой (3.17) для последовательного вычисления приближенных значений интегралов  $I_n$ :

$$\begin{array}{ll} I_1 \approx I_1^* = 1I_0^* - 1 = 0.71828; & I_2 \approx I_2^* = 2I_1^* - 1 = 0.43656; \\ I_3 \approx I_3^* = 3I_2^* - 1 = 0.30968; & I_4 \approx I_4^* = 4I_3^* - 1 = 0.23872; \\ I_5 \approx I_5^* = 5I_4^* - 1 = 0.19360; & I_6 \approx I_6^* = 6I_5^* - 1 = 0.16160; \\ I_7 \approx I_7^* = 7I_6^* - 1 = 0.13120; & I_8 \approx I_8^* = 8I_7^* - 1 = 0.00496; \\ I_9 \approx I_9^* = 9I_8^* - 1 = -0.55360; & I_{10} \approx I_{10}^* = 10I_9^* - 1 = -6.5360. \end{array}$$

Здесь вычисления следует прекратить. Искомые значения интегралов очевидно, положительны, а найденные значения при  $n = 9$  и  $n = 10$  отрицательны. В чем причина появления такой большой ошибки?

В данном примере все вычисления проводились точно, а единственная и, на первый взгляд, незначительная ошибка была сделана при округлении значения  $I_0$  до 6 значащих цифр (заметим, что  $\Delta_0 = |I_0 - I_0^*| \approx 2 \cdot 10^{-6}$ ).

Однако при вычислении  $I_1$  эта ошибка сохранилась, при вычислении  $I_2$  умножилась на  $2!$ , при вычислении  $I_3$  — на  $3!$ , ..., при вычислении  $I_9$  — на  $9!$  и т.д.

<sup>1</sup> Идея примера заимствована из [5], [86].

Таким образом,  $\Delta_n = |I_n - I_n^*| = n! \Delta_0$ . Уже при  $n = 9$  имеем  $9! = 36880$  и поэтому  $\Delta_9 = 9! \Delta_0 \approx 0.73$ .

Если вычисления производятся без ограничений на число  $n$ , то рассматриваемый алгоритм следует признать вычислительно неустойчивым. Ошибки растут пропорционально  $n!$  настолько быстро, что уже при довольно скромных значениях  $n$  попытки добиться приемлемого результата даже за счет увеличения разрядности мантиссы заранее обречены на неудачу.

Как изменить алгоритм, чтобы сделать его устойчивым? Перепишем формулу (3.17) в виде

$$I_{n-1} = \frac{I_n + 1}{n}, \quad n \geq 1 \quad (3.18)$$

и будем вести вычисления значений  $I_n$  в обратном порядке, начиная, например, с  $n = 54$ . Положим  $I_{54} \approx I_{54}^* = 0$ . Так как  $I_{54} \leq e \int_0^1 x^{54} dx = e/55$ , то  $\Delta_{54} \leq e/55 \approx 5 \cdot 10^{-2}$ . Однако при вычислении  $I_{53}$  эта ошибка уменьшится в 54 раза, при вычислении  $I_{52}$  — еще в 53 раза и т.д.

В результате значения  $I_n$  при  $n = 50, \dots, 1$  будут вычислены с шестью верными значащими цифрами. Здесь погрешности не растут, а затухают. Ясно, что модифицированный алгоритм вычислительно устойчив.

Вычислительная неустойчивость алгоритма часто может быть выявлена благодаря анализу устойчивости по входным данным, так как неустойчивость к малым ошибкам округления входных данных автоматически свидетельствует о вычислительной неустойчивости алгоритма.

**Пример 3.27.** Предположим, что величины  $y_n$  для  $n = 1, 2, \dots$  вычисляются по рекуррентной формуле

$$y_n = \alpha_n y_{n-1} + \beta_n, \quad (3.19)$$

а величина  $y_0$  задана. Пусть  $y_0^*$  — заданное приближенное значение величины  $y_0$ . Тогда (если вычисления ведутся абсолютно точно) определяемые по формуле (3.19) приближенные значения содержат ошибки, связанные равенством  $y_n - y_n^* = \alpha_n (y_{n-1} - y_{n-1}^*)$ . Следовательно,  $\Delta(y_n^*) = |\alpha_n| \Delta(y_{n-1}^*)$  и при выполнении условия  $|\alpha_n| \leq 1$  алгоритм устойчив по входным данным, поскольку  $\Delta(y_n^*) \leq \Delta(y_0^*)$  для всех  $n$ . Если же  $|\alpha_n| \geq q > 1$ , то  $\Delta(y_n^*) \geq q^n \Delta(y_0^*)$  и абсолютная погрешность неограниченно возрастает при  $n \rightarrow \infty$ . В этом случае алгоритм неустойчив по входным данным, а потому и вычислительно неустойчив.

Справедливости ради следует заметить, что алгоритм (3.19) был признан нами неустойчивым в случае  $|\alpha_n| \geq q > 1$  при выполнении двух условий, на которых не было достаточно акцентировано внимание. Первое из них состоит в предположении о неограниченной продолжительности вычислительного процесса ( $n \rightarrow \infty$ ), что невозможно на практике. В действительности такой характер неустойчивости говорит о тенденции к неограниченному росту погрешности при неограниченном продолжении вычислений. Правда, если ошибки растут очень быстро, то вычисления могут довольно скоро завершиться аварийным остановом по переполнению. Второе условие касается выбранной меры погрешности. Совсем не обязательно, чтобы рост абсолютной погрешности всегда был неприемлем в конкретных вычислениях. Если он сопровождается сильным ростом точного решения и при этом относительная погрешность остается малой, то алгоритм можно признать относительно устойчивым. По-видимому, при анализе вычислительной устойчивости более естественным является рассмотрение относительных погрешностей.

**Пример 3.28.** Пусть в формуле (3.19) все  $\beta_n = 0$  и  $\alpha_n \neq 0$ . Тогда  $\delta(y_n^*) = \Delta(y_n^*)/|y_n| = |\alpha_n| \Delta(y_{n-1}^*)/|\alpha_n y_{n-1}| = \delta(y_{n-1}^*)$ . Следовательно,  $\delta(y_n^*) = \delta(y_0^*)$  и при любых значениях  $\alpha_n \neq 0$  алгоритм относительно устойчив по входным данным.

### § 3.5. Чувствительность вычислительных алгоритмов к ошибкам округления

Выполнение вычислений на ЭВМ сопровождается появлением вычислительной погрешности, связанной в первую очередь с необходимостью округления результата каждой арифметической операции. Даже если разрядность ЭВМ велика, существует реальная опасность, что выполнение большого числа операций приведет к накоплению погрешности, способной значительно или даже полностью исказить вычисляемый результат. Однако и при небольшом числе действий результат вычислений может оказаться совершенно неправильным, если алгоритм слишком чувствителен к ошибкам округления.

Начинающий вычислитель часто склонен игнорировать ошибки округления. На первых порах при решении простых задач, в особенности если новичок не задумывается о точности найденных решений, его позицию нетрудно понять. Однако решение серьезных задач (когда число арифметических операций превышает миллиарды, в вычис-



ления вкладываются значительные средства, а результат следует получить с гарантированной точностью и за принятые на основании расчетов решения приходится нести ответственность) предполагает совсем иное отношение к вычислительной погрешности.

**1. Порядок выполнения операций.** Решение математической задачи на ЭВМ сводится в конечном итоге к выполнению последовательности простейших арифметических и логических операций. Однако часто одно и то же математическое выражение допускает различные способы вычисления, отличающиеся только порядком выполнения операций. Если вычисления производить точно, то они (при любом способе вычисления) будут приводить к одному результату. Однако результаты вычислений на ЭВМ уже зависят от порядка выполнения операций и различие в вычислительной погрешности может быть весьма значительным.

Рассмотрим простой, но полезный пример вычисления на ЭВМ суммы  $S_N = \sum_{i=1}^N a_i$ . Пусть  $a_i$  — положительные представимые на вычислительной машине числа. В каком порядке следует их суммировать для того, чтобы сделать вычислительную погрешность по возможности минимальной?

Пусть  $S_k = \sum_{i=1}^k a_i$  — частичная сумма, а  $S_k^*$  — ее приближенное значение, вычисляемое по формуле  $S_k^* = S_{k-1}^* \oplus a_k$ . Погрешность значения  $S_k^*$  складывается из погрешности значения  $S_{k-1}^*$  и погрешности выполнения операции  $S_{k-1}^* \oplus a_k$ . Следовательно,  $\bar{\Delta}(S_k^*) = \bar{\Delta}(S_{k-1}^*) + (S_{k-1}^* + a_k)\epsilon_m \approx \bar{\Delta}(S_{k-1}^*) + S_k\epsilon_m$ . Поэтому  $\Delta(S_N^*) \approx S_N\epsilon_m + S_{N-1}\epsilon_m + \dots + S_2\epsilon_m = ((N-1)a_1 + (N-1)a_2 + (N-2)a_3 + \dots + 2a_{N-1} + a_N)\epsilon_m$ .

Так как множитель, с которым входит  $a_i$  в формулу для оценки погрешности, убывает с ростом  $i$ , в общем случае ошибка окажется наименьшей, если суммировать числа в порядке возрастания их значений, начиная с наименьшего.

Иногда неудачно выбранный порядок операций либо приводит к полной потере точности, либо вообще не дает возможности получить результат из-за переполнения.

**Пример 3.29.** Пусть на ЭВМ типа IBM PC требуется вычислить произведение  $v = a_0 \times a_1 \times a_2 \times \dots \times a_{49} \times a_{50}$ , где  $a_i \approx 10^{25-i}$ . Если производить вычисления в естественном порядке, то уже  $a_0 \times a_1 \approx 10^{44}$  дает аварийный останов по переполнению. Вычисление произведения в обратном

порядке сразу же приводит к исчезновению порядка, так как  $a_{50} \times a_{49} \approx 10^{-49} < X_0$ . В результате  $a_{50} \otimes a_{49} = 0$  и после выполнения всех умножений будет получено нулевое значение  $u$ . В данном случае вполне приемлем следующий порядок операций:  $v = a_0 \times a_{50} \times a_1 \times a_{49} \times \dots \times a_{24} \times a_{26} \times a_{25}$ , исключающий возможность переполнения или антипереполнения.

**2. Катастрофическая потеря точности.** Иногда короткая последовательность вычислений приводит от исходных данных, известных с высокой точностью, к результату, содержащему недопустимо мало верных цифр или вообще не имеющему ни одной верной цифры. В этом случае, как было отмечено в § 3.2, принято говорить о катастрофической потере точности. В примере 3.29 мы сталкивались с ситуацией, когда неудачный порядок вычисления произведения привел к неверному нулевому значению результата. Рассмотрим другие примеры.

**Пример 3.30<sup>1</sup>.** Известно, что функция  $e^x$  может быть представлена в виде сходящегося степенного ряда:

$$e^x = \sum_{k=0}^{\infty} \frac{x^k}{k!} = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots + \frac{x^n}{n!} + \dots \quad (3.20)$$

Возможность вычисления значения экспоненты прямым суммированием ряда (3.20) кажется привлекательной. Пусть для вычислений используется 6-разрядная десятичная ЭВМ. Возьмем  $x = -8.1$  и будем вычислять значения частичных сумм до тех пор, пока добавление очередного слагаемого еще меняет значение суммы:

$$e^{-8.1} \approx 1.00000 \oplus 8.10000 \oplus 32.8050 \oplus 88.5737 \oplus 179.362 \oplus 290.566 \oplus \\ \oplus \dots \oplus 16.4111 \oplus 7.81941 \oplus \dots = 0.000649915.$$

В сумму вошло 36 слагаемых и значение очередного (37-го) слагаемого оказалось уже не в состоянии изменить результат. Можно ли считать результат удовлетворительным? Сравнение с истинным значением  $e^{-8.1} \approx 0.000303539$  показывает, что найденное значение не содержит ни одной верной цифры.

В чем причина катастрофической потери точности? Дело в том, что вычисленные слагаемые ряда неизбежно содержат погрешности, причем для некоторых (для слагаемых с 5-го по 13-е) величина погрешности превосходит значение самого искомого результата. Налицо явный дефект алгоритма, к обсуждению которого мы еще вернемся в конце этого параграфа.

В данном случае переход к вычислениям с удвоенной длиной мантиссы позволит получить значение  $e^{-8.1}$  с шестью верными значащими цифрами.

---

<sup>1</sup> Идея примера заимствована из [86].

Однако всего лишь удвоенное значение аргумента  $x = -16.2$  снова возвращает нас к той же проблеме. Поступим иначе. Используя разложение (3.20), вычислим  $e^{8.1} \approx 1.00000 \oplus 8.1000 \oplus 32.8050 \oplus \dots = 3294.47$  и тогда  $e^{-8.1} = 1/e^{8.1} \approx \approx 0.000303539$ . Предложенное изменение алгоритма позволило получить искомое значение на той же 6-разрядной десятичной ЭВМ, но уже с шестью верными значащими цифрами.

Заметим тем не менее, что реальные машинные алгоритмы вычисления  $e^x$  устроены совсем иначе.

Приведем теперь пример, когда к катастрофической потере точности приводит еще более короткая последовательность вычислений.

**Пример 3.31.** Пусть при  $x = 1/490$  на 6-разрядной десятичной ЭВМ вычисляется значение функции

$$y = \cos x - \cos 2x. \quad (3.21)$$

Заметим, что при  $x \approx 0$  величины  $c_1 = \cos x \approx 1 - \frac{x^2}{2}$  и  $c_2 = \cos 2x \approx 1 - 2x^2$  близки. Так как вычисленные их приближенные значения  $c_1^*$  и  $c_2^*$  будут содержать ошибку, то возможна серьезная потеря точности. Действительно,  $c_1^* = 0.999998$ ,  $c_2^* = 0.999992$  и  $y^* = c_1^* - c_2^* = 0.000006$ . При вычитании старшие разряды оказались потерянными и в результате осталась только одна значащая цифра.

Вычисление по эквивалентной формуле  $y = 2 \sin \frac{x}{2} \sin \frac{3x}{2}$ , позволяет избежать вычитания близких чисел и дает значение  $y^* = 0.624741 \cdot 10^{-5}$  с шестью верными цифрами.

Интересно отметить, что  $y \approx 1.5x^2$ , причем использование этой приближенной формулы в данном случае дает 6 верных значащих цифр, в то время как вычисления по формуле (3.21) — только одну верную цифру.

**З а м е ч а н и е.** Не всегда катастрофическая потеря точности в промежуточных вычислениях действительно является катастрофой. Все зависит от того, как в дальнейшем используется результат.

**3. Обусловленность вычислительного алгоритма.** По аналогии с понятием обусловленности математической задачи можно ввести понятие обусловленности вычислительного алгоритма, отражающее чувствительность результата работы алгоритма к малым, но неизбежным ошибкам округления. Вычислительно устойчивый алгоритм называют *хорошо обусловленным*, если малые относительные погрешности округления (характеризуемые числом  $\epsilon_m$ ) приводят к малой относительной

вычислительной погрешности  $\delta(y^*)$  результата  $y^*$ , и *плохо обусловленными*, если вычислительная погрешность может быть недопустимо большой.

Если  $\delta(y^*)$  и  $\epsilon_m$  связаны неравенством  $\delta(y^*) \leq \nu_A \epsilon_m$ , то число  $\nu_A$  следует называть *числом обусловленности вычислительного алгоритма*. Для плохо обусловленного алгоритма  $\nu_A \gg 1$ .

При очень большом значении числа обусловленности алгоритм можно считать практически неустойчивым<sup>1</sup>.

Применим, например, алгоритм, первоначально предложенный в примере 3.26, для вычисления конечной серии из  $N$  интегралов  $I_1, I_2, \dots, I_N$ . Тогда коэффициент роста ошибки  $\nu_A$  окажется конечным. Иными словами, при вычислении конечной серии интегралов алгоритм формально оказывается устойчивым. Тем не менее уже при не очень больших значениях  $N$  он настолько плохо обусловлен, что в практическом плане может считаться неустойчивым.

Для решения хорошо обусловленной задачи нет смысла применять плохо обусловленный алгоритм. Именно такими являются алгоритмы, первоначально предложенные в примерах 3.26 и 3.30.

Вернемся к примеру 3.30. Задача вычисления функции  $e^x$  хорошо обусловлена (см. пример 3.10). Можно ли было предвидеть катастрофическую потерю точности при вычислении значения  $e^{-8.1}$  прямым суммированием ряда (3.20)?

Рассмотрим задачу суммирования ряда  $\sum_{k=0}^{\infty} a_k$  со слагаемыми  $a_k = \frac{x^k}{k!}$ . Каждое из этих слагаемых вычисляется с относительной ошибкой  $\delta(a_k^*) \gtrsim \epsilon_m$ . При  $x < 0$  формула (3.10) с учетом разложения (3.20) дает значение  $\nu_\delta = \frac{\sum_{k=0}^{\infty} \frac{|x|^k}{k!}}{\left| \sum_{k=0}^{\infty} \frac{x^k}{k!} \right|} = e^2 |x|$ . Рост модуля  $x$  (для  $x < 0$ ) приводит к резкому ухудшению обусловленности вычислений. Для  $x = -8.1$ , как в примере 3.30, имеем  $\nu_\delta = e^{16.2} \approx 10^7$ . Поэтому неудивительна полная потеря точности при вычислениях на 6-разрядной десятичной ЭВМ.

Рассмотрим теперь обусловленность алгоритма прямого вычисления по формуле (3.21). Если величина  $x$  не слишком мала ( $2x^2 \gtrsim \epsilon_m$ ), то значения  $c_1^* \approx 1 - \frac{x^2}{2}$  и  $c_2^* \approx 1 - 2x^2$  будут содержать ошибки порядка

<sup>1</sup> Иногда такие плохо обусловленные алгоритмы называют численно неустойчивыми.

$\epsilon_m$ . Поэтому  $\bar{\Delta}(y^*) \sim 2\epsilon_m$ . Учитывая, что  $y \approx 1.5x^2$ , найдем оценку границы относительной погрешности  $\bar{\delta}(y^*) \sim x^{-2}\epsilon_m$ . Число обусловленности  $\nu \sim x^{-2}$  растет с уменьшением  $|x|$ . В случае, когда  $2x^2 \lesssim \epsilon_m$ , в результате вычислений будут получены значения  $c_1^* = 1$ ,  $c_2^* = 1$  и  $y^* = c_1^* - c_2^* = 0$ . Здесь  $\delta(y^*) = |y - y^*|/|y| = 1$  и происходит полная потеря точности.

Если алгоритм, предназначенный для решения хорошо обусловленной задачи, оказался плохо обусловленным, то его следует признать неудовлетворительным и попытаться построить более качественный алгоритм. В примерах 3.30 и 3.31 это удалось сделать сравнительно легко.

Однако для плохо обусловленных задач дело обстоит иначе. Ключ к пониманию дает следующее высказывание [67]: "Если задача плохо обусловлена, то никакие усилия, потраченные на организацию изоциренных вычислений, не могут дать правильных ответов, исключая случайности". Здесь требуется серьезное переосмысление постановки вычислительной задачи.

### § 3.6. Различные подходы к анализу ошибок

**1. Прямой анализ ошибок.** Общий эффект влияния ошибок обычно учитывают следующим образом. Изучают воздействие ошибок входных данных, метода и округлений на получаемый результат  $y^*$  и пытаются оценить некоторую меру близости  $y^*$  к истинному решению  $y$ . Такой метод исследования называют *прямым анализом ошибок*. В большинстве случаев в данной книге мы будем следовать этому традиционному пути. Во многих (но далеко не во всех) случаях оценки погрешности удается получить; однако довольно часто они оказываются сильно завышенными и приводят к неоправданному пессимизму в оценке качества приближенного решения. Реальная величина погрешности  $y - y^*$  часто значительно меньше, чем ее оценка, рассчитанная на самый неблагоприятный случай и выведенная с помощью прямого анализа. Особенно трудным является прямой анализ вычислительной погрешности.

**2. Обратный анализ ошибок.** В последнее время получил широкое распространение другой подход к оценке влияния ошибок. Оказывается, что довольно часто приближенное решение  $y^*$  можно трактовать как точное решение той же задачи, но отвечающее возмущенным ис-

ходным данным  $x^*$ . Оценка величины такого эквивалентного возмущения и является целью *обратного анализа ошибок*.

В прикладных задачах входные данные, как правило, содержат погрешности. Обратный анализ показывает, что ошибки, внесенные в решение в процессе его вычисления, оказываются равносильными некоторым дополнительным ошибкам, внесенным во входные данные. Сопоставление величины эквивалентного возмущения и уровня ошибок входных данных позволяет судить о качестве найденного решения. На рис. 3.5 представлена графическая иллюстрация обратного анализа ошибок. Здесь данное  $x^*$  таково, что решением задачи, соответствующим  $x^*$ , является  $y^*$  — результат приближенного решения задачи с входным данным  $x$ . На рисунке заштрихована область неопределенности входного данного; в пределах этой области входные данные для решающего задачу неразличимы. В представленном случае  $x^*$  оказалось внутри этой области, поэтому результат  $y^*$  следует признать вполне приемлемым.

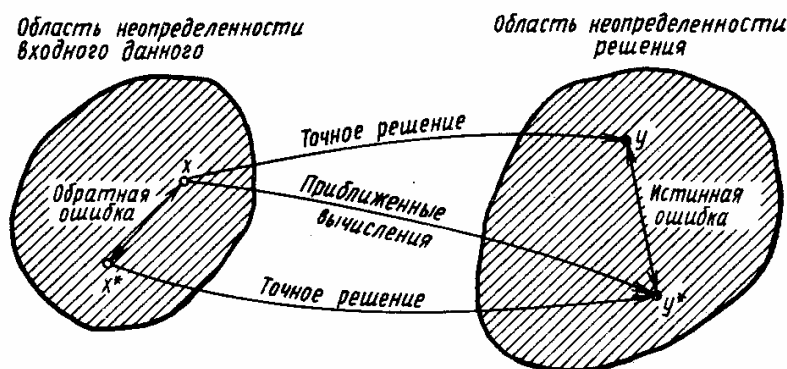


Рис. 3.5

Каждый из указанных двух подходов к оценке погрешности имеет свои достоинства и полезным является разумное их сочетание.

**Пример 3.32.** Пусть на 6-разрядной десятичной ЭВМ вычисляется корень уравнения

$$x^5 - 12.5x^4 + 62.5x^3 - 156.25x^2 + 195.3125x - 97.65625 = 0.$$

При вводе в ЭВМ последние два коэффициента будут округлены до шести значащих цифр и уравнение примет вид

$$P^*(x) = x^5 - 12.5x^4 + 62.5x^3 - 156.25x^2 + 195.313x - 97.6563 = 0. \quad (3.22)$$

Допустим, что некоторый алгоритм, примененный к этому уравнению, дал значение приближенного решения  $x^* = 2.6$ . Следуя логике прямого анализа

ошибок, чтобы оценить качество полученного приближения нужно было бы задаться вопросом: насколько отличается  $x^*$  от истинного решения  $\bar{x}$  уравнения (3.22)? Мы поступим иначе. Подставляя  $x^*$  в левую часть уравнения (3.22), получим значение  $P^*(x^*) = 0.00126$ . Заметим теперь, что  $x^* = 2.6$  является точным решением уравнений

$$\begin{aligned}x^5 - 12.5x^4 + 62.5x^3 - 156.25x^2 + 195.3125x - 97.65626 &= 0, \\x^5 - 12.5x^4 + 62.5x^3 - 156.25x^2 + 195.31252x - 97.656312 &= 0,\end{aligned}$$

которые после округления коэффициентов совпадают с уравнением (3.22) и становятся неотличимы от исходного уравнения. Найденное решение следует признать превосходным с точки зрения "философии" обратного анализа ошибок, так как оно является точным решением задачи, лежащей в пределах области неопределенности задачи (3.22). Рассчитывать на то, что после записи уравнения в виде (3.22) удастся получить лучший ответ, просто бессмысленно. Конечно, это немного обидно, особенно если учесть, что исходное уравнение в действительности есть развернутая запись уравнения  $(x - 2.5)^5 = 0$  и истинным значением корня является  $x = 2.5$ .

Представляется, что значение обратного анализа ошибок недостаточно осознанно, в особенности среди непрофессиональных вычислителей. Этот подход показывает на возможность иного взгляда на оценку качества приближенного решения, а, значит, и на качество многих вычислительных алгоритмов. Сложившийся стереотип заставляет искать приближенное решение  $y^*$  математической задачи, мало отличающееся от ее истинного решения  $y$ . Однако для большинства практических задач в силу неопределенности в постановке и входных данных в действительности существует и область неопределенности решения (см. рис. 3.5). Поскольку эта область неизвестна, оценить степень близости вычисленного решения  $y^*$  к ней очень трудно. Гораздо проще, быть может, получить ответ на аналогичный вопрос для входного данного  $x^*$ , соответствующего решению  $y^*$ . Поэтому можно сформулировать цель вычислений и так: "найти точное решение задачи, которая мало отличается от поставленной задачи" или же так: "найти решение задачи с входным данным  $x^*$ , находящимся в пределах области неопределенности заданного входного данного  $x$ ".

**Пример 3.33.** Пусть для задачи Коши

$$y - \sqrt{y} = \alpha(x)x, \quad y(1) = 2, \tag{3.23}$$

где  $\alpha(x) = 2.6 + 0.01e^{-x}$ , найдено приближенное решение  $y = 2x^2$ . Как оценить его качество?

Условие  $y(1) = 2$ , очевидно, выполнено. Подставляя  $y(x)$  в левую часть уравнения, убеждаемся, что  $y(x)$  удовлетворяет уравнению (3.23) с коэффициентом  $\alpha^* = 4 - \sqrt{2} \approx 2.586$  вместо  $\alpha$ . Обратим внимание на то, что "истинное" значение  $\alpha_0$  коэффициента  $\alpha$  нам в действительности неизвестно и  $\alpha(x)$  — лишь некоторое его приближение. Числовой параметр 2.6 в лучшем случае получен округлением "истинного" значения, и, следовательно,  $\alpha$  может отличаться от  $\alpha_0$  и на 0.05. Так как  $|\alpha^* - \alpha| \leq 0.03$ , то в силу естественной неопределенности в постановке задачи функция  $y = 2x^2$  с позиции обратного анализа ошибок может считаться таким же равноправным решением поставленной задачи, как и найденное сколь угодно точно решение задачи (3.23). Во всяком случае теперь для того, чтобы отказаться от найденного приближенного решения, нужны довольно веские аргументы.

Подчеркнем, что в основе методов решения некорректных и плохо обусловленных задач также лежит существенное переосмысление постановок вычислительных задач.

**3. Статистический анализ ошибок.** Даже для простых алгоритмов строгий анализ влияния ошибок округления очень сложен. При большом числе выполняемых операций гарантированные оценки погрешности, рассчитанные на самый неблагоприятный случай, как правило, бывают сильно завышенными.

Можно надеяться на то, что появляющиеся в реальном вычислительном процессе ошибки округления случайны и их взаимное влияние приводит к определенной компенсации результирующей ошибки. Статистический анализ ошибок, исходящий из предположения об их случайности, направлен на исследование не максимально возможных, а наиболее вероятных ошибок.

Для сравнения покажем отличие в результатах на примере задачи вычисления суммы  $S_N = \sum_{k=1}^N a_k$  большого числа положительных слагаемых. Гарантированная оценка погрешности дает значение относительной погрешности  $\delta(S_N^*)$ , растущее пропорционально  $N$ . В то же время статистический анализ показывает, что если ошибки округления являются случайными с нулевым средним значением, то  $\delta(S_N^*)$  растет пропорционально  $\sqrt{N}$ , т.е. гораздо медленнее. К сожалению, на тех ЭВМ, где округление производится усечением, последнее предположение не выполнено, так как ошибки округления смещены в одну сторону и поэтому имеют ненулевое среднее значение. Здесь  $\delta(S_N^*)$  растет опять пропорционально  $N$ .

**4. Некоторые нестрогие способы анализа.** Распространенным мето-



дом оценки влияния вычислительной погрешности является расчет с обычной и удвоенной точностью. Если результаты двух вычислений получаются существенно различными, это является свидетельством плохой обусловленности алгоритма. В то же время есть надежда на то, что совпадающие в ответах цифры верны.

Примерно такие же суждения о чувствительности решения к ошибкам округления можно сделать, если провести вычисления на двух различных вычислительных машинах или использовать различные компиляторы. Разумеется, такое исследование имеет смысл провести на одном-двух типичных примерах до начала массовых однотипных расчетов.

Влияние ошибок во входных данных на результат вычислений можно увидеть, если решить задачу несколько раз, изменяя случайным образом входные данные в пределах ошибки их задания. Проведя такой эксперимент несколько раз, можно грубо оценить погрешность решения, вызванную погрешностями входных данных.

### **§ 3.7. Требования, предъявляемые к вычислительным алгоритмам**

В § 3.4 и 3.5 были сформулированы два важнейших требования — корректность и хорошая обусловленность. Помимо них к алгоритмам предъявляется еще целый ряд существенных требований.

**1. Требования к абстрактным алгоритмам.** К числу этих требований относятся: 1) экономичность; 2) надлежащая точность; 3) экономия памяти; 4) простота.

*Экономичность* алгоритма измеряется числом элементарных операций, необходимых для его реализации, и в конечном итоге сводится к затратам машинного времени. Это требование формулируют иногда как требование максимальной скорости исполнения алгоритма. Экономичность особенно важна при массовых расчетах. Естественно, что при создании алгоритмов большое внимание уделяют минимизации числа операций. Для некоторых задач разработаны алгоритмы, требующие минимально возможного числа операций. Пример такого алгоритма — схема Горнера (см. пример 3.19). Отметим, что ряд математических алгоритмов, созданных в домашний период, оказался удивительно неэкономичным. Приведем классический пример такого алгоритма.

**Пример 3.34** (правило Крамера<sup>1</sup>). Для решения системы линей-

---

<sup>1</sup> Габриэль Крамер (1704 — 1752) — швейцарский математик.

ных алгебраических уравнений  $Ax = b$  порядка  $m$  по правилу Крамера предлагается вычислять компоненты вектора  $x$  как отношения специальным образом построенных определителей:  $x_i = \Delta_i / \Delta$ ,  $i = 1, 2, \dots, m$ . Если вычислять определитель непосредственно по его определению, то нужно выполнить  $(m-1)m!$  умножений и  $m!$  сложений. Пусть для вычислений используется ЭВМ с производительностью  $10^6$  умножений в секунду и решается система с числом неизвестных  $m = 15$ , весьма скромным для приложений. Тогда вычисление только одного определителя потребует  $14 \cdot 15! \approx 1.8 \cdot 10^{13}$  умножений, в результате чего на вычисление решения уйдет около 10 лет непрерывной работы ЭВМ. Вместе с тем для решения той же системы на той же ЭВМ методом Гаусса (см. гл. 5) потребуется примерно 0.002 с. Естественно, что как вычислительный алгоритм правило Крамера следует забраковать.

Даже для самых простых задач выбор экономичного алгоритма может дать существенное уменьшение числа операций.

**Пример 3.35.** Пусть требуется вычислить  $x^n$ , где  $n$  — натуральное число. Вычисление этой величины последовательным умножением на  $x$  предполагает выполнение  $n-1$  операций умножения. Нетрудно убедиться в том, что этот способ не самый экономичный. Например,  $x^{64}$  можно найти, выполнив не 63, а всего 6 операций умножения, если последовательным возведением в квадрат вычислить  $x^2, x^4, x^8, x^{16}, x^{32}, x^{64}$ .

В общем случае представим  $n$  в виде разложения (2.25) по степеням двойки (именно так число  $n$  хранится в памяти ЭВМ). Тогда

$$x^n = (x^{2^L})^{\alpha_L} \cdot (x^{2^{L-1}})^{\alpha_{L-1}} \cdot (x^2)^{\alpha_1} \cdot x^{\alpha_0}. \quad (3.24)$$

Заметим, что в произведении (3.24) следует учитывать при вычислении только те сомножители, для которых  $\alpha_i \neq 0$  (т.е.  $\alpha_i = 1$ ). Алгоритм, основанный на разложении (3.24), называется *бинарным алгоритмом*. Он позволяет найти  $x^n$  не более чем за  $2 \log_2 n$  операций умножения.

Требование *точности* означает, что вычислительный алгоритм должен давать решение задачи с заданной или приемлемой для задачи точностью  $\varepsilon$ .

Важным является требование *экономии памяти*. Хотя в последнее время доступная память ЭВМ существенно расширилась, для "больших" задач требование экономии памяти может в ряде случаев стать основным. Интерес к экономному размещению информации в памяти возрастает в связи с более широким использованием персональных ЭВМ для решения научно-технических и инженерных задач.

Учитывая необходимость дальнейшей программной реализации алгоритма, подчеркнем, что *простота алгоритма* также является весьма желательным его свойством.

**2. Требования к программным реализациям алгоритмов.** К настоящему времени выработан ряд требований к программам, реализующим вычислительные алгоритмы и предназначенным для длительного и широкого использования. Перечислим некоторые из них: 1) надежность; 2) работоспособность (робастность); 3) переносимость (портатбельность); 4) поддерживаемость; 5) простота в использовании и др. Рассмотрим эти требования более подробно.

*Надежность* программы означает, что она не содержит ошибок и вычисляет именно тот результат, для которого она предназначена. *Работоспособность (робастность)* включает в себя надежность и предполагает, что программа способна выявлять недопустимые исходные данные, обнаруживать различные критические для задачи или алгоритма ситуации. Робастная программа реагирует на такие ситуации приемлемым для пользователя образом. Она составлена так, чтобы исключить какие-либо аварийные остановы, в том числе по переполнению, из-за деления на нуль, неудачной попытки применить операцию извлечения квадратного корня или взятия логарифма от отрицательного числа.

Алгоритм может "потерпеть неудачу" при решении задачи, если заданное входное данное не является для него допустимым. Конечно, в простых ситуациях пользователь должен сам различать допустимые для алгоритма входные данные от недопустимых. Однако чаще всего сделать это до вычислений очень трудно или невозможно, и в программе должен быть предусмотрен анализ данных и сообщение пользователю о недопустимых или сомнительных данных. Необходимо исключить ситуацию, характерную для некачественных программ, когда реакцией на задание данных, при которых алгоритм не может по объективным причинам найти решение задачи, является аварийный останов или же выдача внешне вполне правдоподобного, но совершенно бессмысленного результата.

*Переносимость (портатбельность)* означает, что программа может работать на различных ЭВМ без изменения или с незначительными изменениями. Всякая характеристика ЭВМ, используемая в программе (например, значение машинного эпсилон  $\epsilon_m$ ), должна или вычисляться самой программой, или задаваться пользователем.

*Поддерживаемость* означает прежде всего требование легкости модификации. Для того чтобы была возможность внесения в программу изменений с минимальной вероятностью появления ошибок, она должна быть составлена максимально ясно и логично. Полезно вносить в текст программы содержательные комментарии. Разобраться в плохо составленной программе может оказаться труднее, чем создать новую. Поддерживаемая программа должна быть хорошо документирована.

Плохое описание программы в лучшем случае способно вызвать к ней недоверие, а в худшем — может не позволить пользователю правильно ее эксплуатировать. К сожалению, нередко ситуация, когда предназначенная для широкого использования программа настолько плохо документирована, что пользователь предпочитает потратить время на написание аналогичной программы (возможно, гораздо худшего качества) либо вообще отказаться от решения задачи.

*Простота в использовании программы* — весьма желательное, но трудно достижимое свойство. Зачастую добиться простоты в использовании можно только жертвуя надежностью или экономичностью. Существует ряд широко используемых программ, которые, в первую очередь, популярны, благодаря простоте в использовании.

**3. Противоречивость требований.** Можно продолжить перечисление требований к вычислительным алгоритмам, добавив, например, требования универсальности и гибкости. Однако нетрудно понять, что сформулированные требования противоречивы. Большинство из них вступает в противоречие с экономичностью, выраженной через затраты машинного времени. В разных ситуациях на первый план может выступать то или иное требование и, удовлетворяя в большей степени одним требованиям, программа с неизбежностью в меньшей степени удовлетворяет другим. Это частично объясняет наличие большого числа программ, предназначенных для решения одной и той же задачи.

Естественно, что хорошая программа, которую можно предъявить для широкого использования, не может быть простой. Следует признать, что составление таких программ — это работа, требующая высокой квалификации и специальных знаний. Ее выполняют специалисты по созданию математического обеспечения ЭВМ. Рядовой пользователь должен по возможности стремиться максимально использовать стандартные программы, а не создавать новые.

### § 3.8. Дополнительные замечания

1. Учебное пособие [79] можно рассматривать как введение в теорию методов решения некорректных задач. Ее удачно дополняют следующие книги: [7], [59], [80]. Отметим, что [80] содержит не только теорию и алгоритмы, но и тексты соответствующих программ.

2. Весьма содержательное изложение проблемы обусловленности вычислительных задач и обратного анализа ошибок содержится в [67]. Здесь же подробно обсуждаются проблема создания высококачественного математического обеспечения и требования, предъявляемые к вычислительным алгоритмам.

## Глава 4

### МЕТОДЫ ОТЫСКАНИЯ РЕШЕНИЙ НЕЛИНЕЙНЫХ УРАВНЕНИЙ

В этой главе рассматривается задача отыскания корней нелинейных уравнений и излагаются методы ее решения. Это делается несколько подробнее, чем обычно принято в учебниках по численным методам. Дело в том, что нелинейное уравнение представляет собой редкий пример задачи, которая может быть сравнительно полно исследована элементарными средствами и допускает наглядные геометрические иллюстрации. В то же время многие проблемы, возникающие при отыскании корней нелинейных уравнений, типичны, а некоторые методы их решения (в особенности метод простой итерации и метод Ньютона) допускают широкие обобщения и играют в вычислительной математике фундаментальную роль.

#### § 4.1. Постановка задачи. Основные этапы решения

1. **Постановка задачи.** Задача отыскания корней нелинейного уравнения с одним неизвестным вида

$$f(x) = 0 \tag{4.1}$$

имеет многовековую историю, но не потеряла свою актуальность и в наши дни. Она часто возникает как элементарный шаг при решении различных научных и технических проблем. Напомним, что *корнем* (или *решением*) уравнения (4.1) называется значение  $\bar{x}$ , при котором  $f(\bar{x}) = 0$ .

Для справедливости большинства рассуждений данной главы достаточно предположить, что в окрестности каждого из искомых корней функция  $f(x)$  дважды непрерывно дифференцируема.

Корень  $\bar{x}$  уравнения (4.1) называется *простым*, если  $f'(\bar{x}) \neq 0$ . В противном случае (т. е. в случае  $f'(\bar{x}) = 0$ ) корень  $\bar{x}$  называется *кратным*. Целое число  $m$  назовем *кратностью корня  $\bar{x}$* , если  $f^{(k)}(\bar{x}) = 0$  для  $k = 1, 2, \dots, m-1$  и  $f^{(m)}(\bar{x}) \neq 0$ . Геометрически корень  $\bar{x}$  соответствует точке пересечения графика функции  $y = f(x)$  с осью  $Ox$ . Корень  $\bar{x}$  является простым, если график пересекает ось  $Ox$  под ненулевым углом, и кратным, если пересечение происходит под нулевым углом. Функция  $f(x)$ , график которой изображен на рис. 4.1, имеет четыре корня. Корни  $\bar{x}_1$  и  $\bar{x}_3$  — простые,  $\bar{x}_2$  и  $\bar{x}_4$  — кратные.

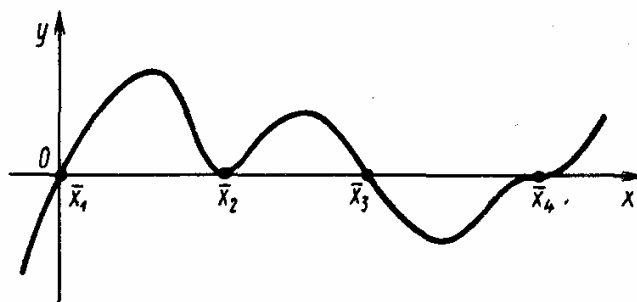


Рис. 4.1

Задача отыскания простых корней является существенно более простой (и чаще встречающейся), чем задача отыскания кратных корней. В действительности большинство методов решения уравнения (4.1) ориентировано именно на вычисление простых корней.

**2. Уточнение постановки задачи.** В конкретной задаче часто интерес представляют не все корни уравнения, а лишь некоторые из них. Тогда постановку задачи уточняют, указывая на то, какие из корней подлежат определению (положительные корни, корни из заданного интервала, максимальный из корней и т.д.).

В подавляющем большинстве случаев представить решение уравнения (4.1) в виде конечной формулы оказывается невозможным. Даже для простейшего алгебраического уравнения  $n$ -й степени

$$x^n + a_{n-1}x^{n-1} + \dots + a_1x + a_0 = 0 \quad (4.2)$$

явные формулы, выражающие его корни через коэффициенты с помощью конечного числа арифметических операций и извлечения корней степени не выше  $n$ , найдены<sup>1</sup> лишь при  $n = 2, 3, 4$ . Однако уже для

---

<sup>1</sup> Алгебраические уравнения третьей и четвертой степени не поддавались усилиям математиков около 2000 лет. Эту задачу решили итальянские математики эпохи Ренессанса: Сципион дель Ферро (1456—1526), Никколо Тарталья (1500—1557), Джироламо Кардано (1501—1576), Людовико Феррари (1522—1565).

уравнений пятой и более высоких степеней таких формул не существует. Этот замечательный факт, известный как теорема Абеля, был установлен в 30-е годы XIX в. Н. Абелем<sup>1</sup> и Э.Галуа<sup>2</sup>.

Невозможность найти точное решение нелинейного уравнения кажется огорчительной. Однако нужно признать, что желание найти точное числовое значение решения вряд ли следует считать разумным. Во-первых, в реальных исследованиях зависимость  $y = f(x)$  является лишь приближенным описанием, моделирующим истинную связь между параметрами  $y$  и  $x$ . Поэтому точное решение  $\bar{x}$  уравнения (4.1) все равно является лишь приближенным значением того параметра  $x$ , который в действительности соответствует значению  $y = 0$ . Во-вторых, даже если уравнение (4.1) допускает возможность нахождения решения в виде конечной формулы, то результат вычислений по этой формуле почти с неизбежностью содержит вычислительную погрешность и поэтому является приближенным.

**Пример 4.1.** Предположим, что исследование некоторого явления привело к необходимости решить уравнение

$$x^2 - 3.3x + 2.7 = 0. \quad (4.3)$$

Воспользовавшись формулами (3.2) для корней квадратного уравнения, получим значения  $\bar{x}_1 = 1.5$ ,  $\bar{x}_2 = 1.8$ . Найдены ли нами точные значения параметра  $x$ ? Очевидно, нет. Скорее всего коэффициенты уравнения (4.3) известны приближенно и в лучшем случае они представляют округленные значения "истинных" коэффициентов. В действительности можно лишь утверждать, что  $\bar{x}_1 \approx 1.5$ ,  $\bar{x}_2 \approx 1.8$ .

Предположим теперь, что "истинный" вид уравнения (4.3) таков:  $x^2 - 3.3287x + 2.6631 = 0$ . Тогда точные значения параметра можно вычислить по формуле  $x_{1,2} = (3.3287 \pm \sqrt{3.3287^2 - 4 \cdot 2.6631})/2$ . Однако она лишь указывает на то, какие операции и в каком порядке следует выполнить. В данном случае точное вычисление по формуле невозможно, так как она содержит операцию извлечения квадратного корня. Вычисленные по ней значения  $\bar{x}_1$ ,  $\bar{x}_2$  неизбежно окажутся приближенными.

---

<sup>1</sup> Нильс Хенрик Абель (1802—1829) — норвежский математик. Теорема, о которой идет речь, была доказана им в возрасте около 22 лет.

<sup>2</sup> Эварист Галуа (1811—1832) — французский математик, один из создателей теории групп.

В дальнейшем мы откажемся от попыток найти точные значения корней уравнения (4.1) и сосредоточим внимание на методах решения более реалистичной задачи приближенного вычисления корней с заданной точностью  $\varepsilon$ .

В данной главе под задачей отыскания решений уравнения (4.1) будем понимать задачу вычисления с заданной точностью  $\varepsilon$  конечного числа подлежащих определению корней этого уравнения.

**3. Основные этапы решения.** Решение задачи отыскания корней нелинейного уравнения осуществляют в два этапа. Первый этап называется *этапом локализации* (или *отделения*) *корней*, второй — *этапом итерационного уточнения корней*.

**Локализация корней.** Отрезок  $[a, b]$ , содержащий только один корень  $\bar{x}$  уравнения (4.1), называют *отрезком локализации* корня  $\bar{x}$ . Цель этапа локализации считают достигнутой, если для каждого из подлежащих определению корней удалось указать отрезок локализации (его длину стараются по возможности сделать минимальной).

Прежде чем переходить непосредственно к отысканию отрезков локализации, имеет смысл провести предварительное исследование задачи для выяснения того, существуют ли вообще корни уравнения (4.1), сколько их и как они расположены на числовой оси.

Способы локализации корней многообразны, и указать универсальный метод не представляется возможным. Иногда отрезок локализации известен либо он определяется из физических соображений. В простых ситуациях хороший результат может давать графический метод (см. пример 4.2). Широко применяют построение таблиц значений функций  $f$  вида  $y_i = f(x_i)$ ,  $i = 1, 2, \dots, n$ . При этом способе локализации о наличии на отрезке  $[x_{i-1}, x_i]$  корня судят по перемене знака функции на концах отрезка (см. пример 4.3). Основанием для применения указанного способа служит следующая хорошо известная теорема математического анализа.

**Теорема 4.1.** Пусть функция  $f$  непрерывна на отрезке  $[a, b]$  и принимает на его концах значения разных знаков, т. е.  $f(a) \cdot f(b) < 0$ . Тогда отрезок  $[a, b]$  содержит по крайней мере один корень уравнения  $f(x) = 0$ .

К сожалению, корень четной кратности не удастся локализовать на основании перемены знака с помощью даже очень подробной таблицы.

Дело в том, что в малой окрестности такого корня (например, корня  $\bar{x}_2$  на рис. 4.1) функция  $f$  имеет постоянный знак.

Важно подчеркнуть, что далеко не всегда для успешного отыскания



корня  $\bar{x}$  уравнения (4.1) необходимо полное решение задачи локализации. Часто вместо отрезка локализации достаточно найти хорошее начальное приближение  $x^{(0)}$  к корню  $\bar{x}$ .

**Пример 4.2.** Локализуем корни уравнения

$$4(1 - x^2) - e^x = 0. \quad (4.4)$$

Для этого преобразуем уравнение к виду  $1 - x^2 = 0.25e^x$  и построим графики

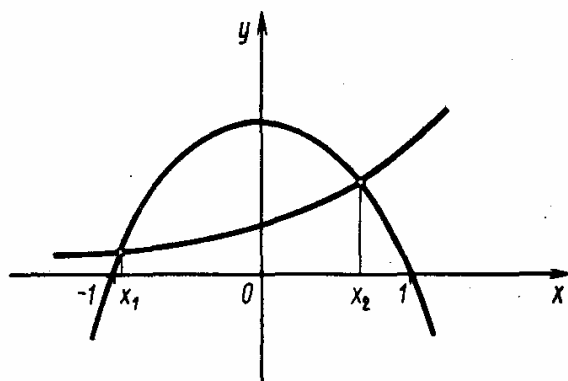


Рис. 4.2

функций  $y = 1 - x^2$  и  $y = 0.25e^x$  (рис. 4.2). Абсциссы точек пересечения этих графиков являются корнями данного уравнения. Из рис. 4.2 видно, что уравнение имеет два

корня  $\bar{x}_1$  и  $\bar{x}_2$ , расположенные на отрезках  $[-1, 0]$  и  $[0, 1]$ . Убедимся, что функция  $f(x) = 4(1 - x^2) - e^x$  принимает на концах указанных отрезков значения разных знаков. Действительно,  $f(-1) = -e^{-1} < 0$ ,  $f(0) = 3 > 0$ ,  $f(1) = -e < 0$ .

Следовательно, в силу теоремы 4.1 на каждом из отрезков  $[-1, 0]$  и  $[0, 1]$  находится по крайней мере один корень.

**Пример 4.3.** Локализуем корни уравнения

$$x^3 - 1.1x^2 - 2.2x + 1.8 = 0.$$

Для этого составим таблицу значений функции  $f(x) = x^3 - 1.1x^2 - 2.2x + 1.8$  на отрезке  $[-2, 2]$  с шагом 0.4.

Т а б л и ц а 4.1

$x$	-2.0	-1.6	-1.2	-0.8	-0.4	0.0
$f(x)$	-6.200	-1.592	1.128	2.344	2.440	1.800

Продолжение табл. 4.1

$x$	0.4	0.8	1.2	1.6	2.0
$f(x)$	0.808	-0.152	-0.696	-0.440	1.000

Из табл. 4.1 видно, что функция  $f$  меняет знак на концах отрезков  $[-1.6, -1.2]$ ,  $[0.4, 0.8]$ ,  $[1.6, 2.0]$ . Теорема 4.1 дает основание утверждать, что каждый из этих отрезков содержит по крайней мере один корень. Учитывая, что в силу основной теоремы алгебры многочлен третьей степени не может иметь более трех корней, заключаем, что полученные три отрезка содержат ровно по одному корню. Таким образом, корни локализованы.

**Итерационное уточнение корней.** На этом этапе для вычисления каждого из корней с точностью  $\varepsilon > 0$  используют тот или иной итерационный метод, позволяющий построить последовательность  $x^{(0)}, x^{(1)}, \dots, x^{(n)}, \dots$  приближений к корню  $\bar{x}$ .

Общее представление об итерационных методах и основные определения были даны в § 3.3. Введем дополнительно некоторые определения.

Итерационный метод называют *одношаговым*, если для вычисления очередного приближения  $x^{(n+1)}$  используется только одно предыдущее приближение  $x^{(n)}$  и *k-шаговым*, если для вычисления  $x^{(n+1)}$  используются  $k$  предыдущих приближений  $x^{(n-k+1)}, x^{(n-k+2)}, \dots, x^{(n)}$ . Заметим, что для построения итерационной последовательности одношаговым методом требуется задание только одного начального приближения  $x^{(0)}$ , в то время как при использовании  $k$ -шагового метода —  $k$  начальных приближений  $x^{(0)}, x^{(1)}, \dots, x^{(k-1)}$ .

Скорость сходимости — одна из важнейших характеристик итерационных методов. Говорят, что *метод сходится со скоростью геометрической прогрессии*, знаменатель которой  $q < 1$ , если для всех  $n$  справедлива следующая оценка:

$$|x^{(n)} - \bar{x}| \leq c_0 q^n. \quad (4.5)$$

Как нетрудно видеть, из оценки (4.5) действительно вытекает сходимость метода.

Пусть одношаговый итерационный метод обладает следующим свойством: существует  $\sigma$ -окрестность корня  $\bar{x}$  такая, что если приближение  $x^{(n)}$  принадлежит этой окрестности, то справедлива оценка

$$|x^{(n+1)} - \bar{x}| \leq C |x^{(n)} - \bar{x}|^p, \quad (4.6)$$

где  $C > 0$  и  $p \geq 1$  — постоянные. В этом случае число  $p$  называют *порядком сходимости метода*. Если  $p = 1$  и  $C < 1$ , то говорят, что метод обладает *линейной скоростью сходимости* в указанной  $\sigma$ -окрестности корня. Если  $p > 1$ , то принято говорить о *сверхлинейной скорости сходимости*. При  $p = 2$  скорость сходимости называют *квадратной*.

точной, а при  $p = 3$  — кубической. При наличии оценки (4.6) у  $k$ -шагового метода (при  $k > 1$ ) число  $p$  также будем называть порядком сходимости метода.

**Л е м м а 4.1.** Пусть одношаговый итерационный метод обладает линейной скоростью сходимости в некоторой  $\sigma$ -окрестности корня  $\bar{x}$ . Тогда при любом выборе начального приближения  $x^{(0)}$  из  $\sigma$ -окрестности корня  $\bar{x}$  итерационная последовательность  $x^{(n)}$  не выходит за пределы этой окрестности, метод сходится со скоростью геометрической прогрессии со знаменателем  $q = C$  и имеет место следующая оценка погрешности:

$$|x^{(n)} - \bar{x}| \leq q^n |x^{(0)} - \bar{x}|, \quad n \geq 0. \quad (4.7)$$

□ Заметим, что принадлежность  $x^{(n)}$  окрестности  $(\bar{x} - \sigma, \bar{x} + \sigma)$  является следствием неравенства (4.7). В самом деле, так как  $q < 1$ , то  $|x^{(n)} - \bar{x}| \leq |x^{(0)} - \bar{x}| < \sigma$ . Сходимость  $x^{(n)}$  к  $\bar{x}$  также вытекает из (4.7).

Справедливость неравенства (4.7) установим методом индукции.

При  $n = 0$  оно переходит в очевидное:  $|x^{(0)} - \bar{x}| \leq |x^{(0)} - \bar{x}|$ .

Пусть неравенство (4.7) выполнено при  $n = m - 1$ . Тогда

$$|x^{(m)} - \bar{x}| \leq q |x^{(m-1)} - \bar{x}| \leq q^m |x^{(0)} - \bar{x}|,$$

т. е. неравенство выполнено и при  $n = m$ . ■

**Л е м м а 4.2.** Пусть  $k$ -шаговый итерационный метод в некоторой  $\sigma$ -окрестности корня  $\bar{x}$  имеет  $p$ -й порядок сходимости. Выберем  $\delta > 0$ , так, чтобы выполнялись неравенства  $\delta \leq \sigma$  и  $C\delta^{p-1} < 1$ , где  $C$  — постоянная из неравенства (4.6). Тогда при любом выборе начального приближения  $x^{(0)}$  из  $\delta$ -окрестности корня  $\bar{x}$  итерационная последовательность  $x^{(n)}$  не выходит за пределы этой окрестности, метод сходится и справедлива оценка

$$|x^{(n)} - \bar{x}| \leq C_1 q^{p^n}, \quad n \geq 0, \quad (4.8)$$

где  $q = C_1^{1/p} |x^{(0)} - \bar{x}|$ ,  $C_1 = C^{1/(p-1)}$ .

□ Заметим, что принадлежность  $x^{(n)}$  окрестности  $(\bar{x} - \delta, \bar{x} + \delta)$  является следствием неравенства (4.8). В самом деле, так как  $q < 1$  и  $1 \leq p^n$ , то из (4.8) вытекает, что  $|x^{(n)} - \bar{x}| \leq C_1 q = |x^{(0)} - \bar{x}| < \delta$ .

Сходимость  $x^{(n)}$  к  $\bar{x}$  также следует из (4.8).

Справедливость неравенства (4.8) установим методом индукции. При  $n = 0$  оно переходит в очевидное:  $|x^{(0)} - \bar{x}| \leq |x^{(0)} - \bar{x}|$ . Пусть неравенство (4.8) выполнено при  $n = m - 1$ . Докажем, что оно верно и при  $n = m$ . Используя условие (4.6), получаем

$$|x^{(m)} - \bar{x}| \leq C|x^{(m-1)} - \bar{x}|^p \leq C(C_1 q^{p^{m-1}})^p = C_1 q^{p^m}. \blacksquare$$

С помощью доказанных лемм исследование сходимости итерационных методов сводится только к получению оценки (4.6).

#### § 4.2. Обусловленность задачи вычисления корня

Пусть  $\bar{x}$  — корень уравнения (4.1), подлежащий определению. Будем считать, что входными данными для задачи вычисления корня  $\bar{x}$  являются значения  $f(x)$  функции  $f$  в малой окрестности корня. Так как значения  $f(x)$  будут вычисляться на ЭВМ по некоторой программе, то в действительности задаваемые значения являются приближенными и их следует обозначать через  $f^*(x)$ . Ошибки в  $f^*(x)$  могут быть связаны не только с неизбежными ошибками округления, но и с использованием для вычисления значений функции  $f$  приближенных методов. К сожалению, нельзя ожидать, что в окрестности корня относительная погрешность  $\delta(f^*)$  окажется малой. Достаточно обратиться к примерам 2.11 и 3.11, чтобы установить, что для чрезвычайно простых функций  $y = 1 - x$  и  $y = \sin x$  в окрестности корней  $\bar{x} = 1$  и  $\bar{x} = \pi$  значения этих функций не могут быть найдены с малой относительной погрешностью. Реально рассчитывать можно лишь на то, что малой окажется абсолютная погрешность вычисления значений функции.

Будем предполагать, что в достаточно малой окрестности корня выполняется неравенство  $|f(x) - f^*(x)| < \bar{\Delta}$ , где  $\bar{\Delta} = \bar{\Delta}(f^*)$  — граница абсолютной погрешности. Сама погрешность корня ведет себя крайне нерегулярно и в первом приближении может восприниматься пользователем как некоторая случайная величина. На рис. 4.3, а представлена идеальная ситуация, отвечающая исходной математической постановке задачи, а на рис. 4.3, б — реальная ситуация, соответствующая вычислениям значений функции  $f$  на ЭВМ.

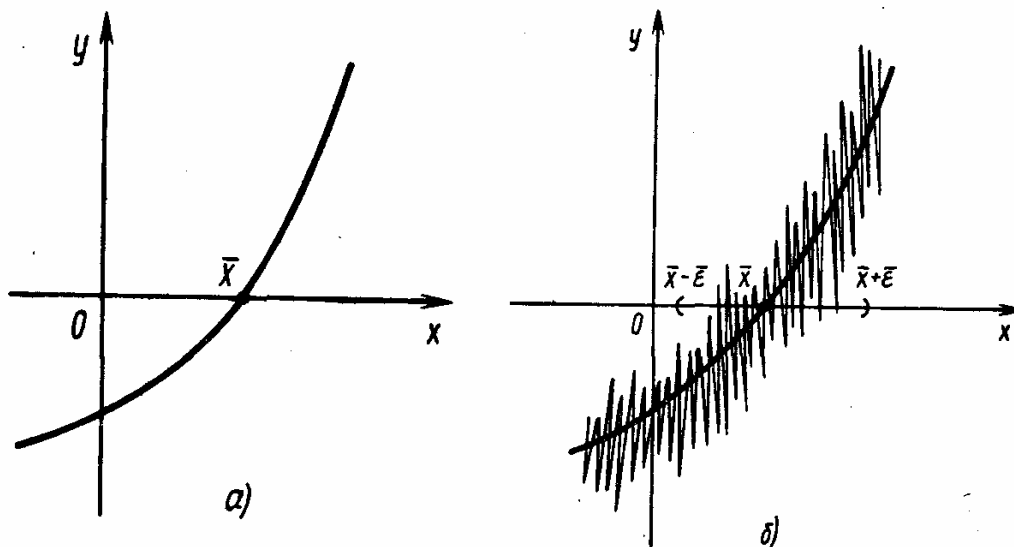


Рис. 4.3

Если функция  $f$  непрерывна, то найдется такая малая окрестность  $(\bar{x} - \bar{\epsilon}, \bar{x} + \bar{\epsilon})$  корня  $\bar{x}$ , имеющая радиус  $\bar{\epsilon} > 0$ , в которой выполняется неравенство

$$|f(x)| < \bar{\Delta}. \quad (4.9)$$

Для  $x \in (\bar{x} - \bar{\epsilon}, \bar{x} + \bar{\epsilon})$  знак вычисленного значения  $f^*(x)$ , вообще говоря, не обязан совпадать со знаком  $f(x)$  и, следовательно, становится невозможным определить, какое именно значение  $x$  из интервала  $(\bar{x} - \bar{\epsilon}, \bar{x} + \bar{\epsilon})$  обращает функцию  $f$  в нуль (рис. 4.3, б).

Будем называть этот интервал *интервалом неопределенности корня*  $\bar{x}$ . Найдем оценку величины  $\bar{\epsilon}$ . Пусть корень  $\bar{x}$  — простой. Для близких к  $\bar{x}$  значений  $x$  справедливо приближенное равенство

$$f(x) \approx f(\bar{x}) + f'(\bar{x})(x - \bar{x}) = f'(\bar{x})(x - \bar{x}).$$

Поэтому неравенство (4.9) примет вид  $|f'(\bar{x})(x - \bar{x})| \lesssim \bar{\Delta}$ , откуда получаем

$$\bar{x} - \frac{\bar{\Delta}}{|f'(\bar{x})|} \lesssim x \lesssim \bar{x} + \frac{\bar{\Delta}}{|f'(\bar{x})|}.$$

Следовательно,

$$\bar{\epsilon} \approx \nu_{\Delta} \bar{\Delta} (f^*). \quad (4.10)$$

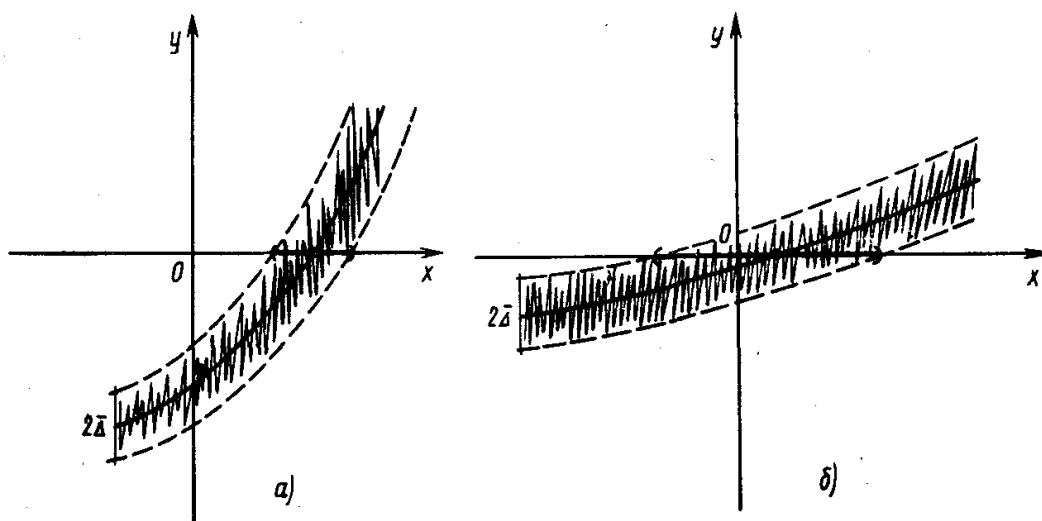


Рис. 4.4

Здесь  $\nu_{\Delta} = \frac{1}{|f'(\bar{x})|}$  — число, которое в рассматриваемой задаче играет роль абсолютного числа обусловленности. Действительно, если  $\bar{x}^*$  — корень уравнения  $f^*(x) = 0$ , то  $|f'(\bar{x}^*)| < \bar{\Delta}$  и тогда выполнено неравенство

$$|\bar{x} - \bar{x}^*| \leq \bar{\Delta}(\bar{x}^*) \leq \bar{\epsilon} \approx \nu_{\Delta} \bar{\Delta}(f^*). \quad (4.11)$$

Заметим, что радиус интервала неопределенности прямо пропорционален погрешности  $\bar{\Delta}$  вычисления значения  $f$ . Кроме того,  $\bar{\epsilon}$  возрастает (обусловленность задачи ухудшается) с уменьшением  $|f'(\bar{x})|$ , т. е. с уменьшением модуля тангенса угла наклона, под которым график функции пересекает ось  $Ox$  (рис. 4.4, а, б).

Если же  $f'(\bar{x}) = 0$  (т. е. корень  $\bar{x}$  — кратный), то формула (4.10) уже не верна. Пусть кратность корня равна  $m$ . Тогда в силу формулы Тейлора<sup>1</sup> справедливо приближенное равенство

$$f(x) \approx f(\bar{x}) + f'(\bar{x})(x - \bar{x}) + \frac{f''(\bar{x})}{2!} (x - \bar{x})^2 + \dots + \frac{f^{(m)}(\bar{x})}{m!} (x - \bar{x})^m,$$

<sup>1</sup> Брук Тейлор (1685—1731) — английский математик и философ. Широко известная формула разложения функции в степенной ряд была получена им в 1712 г.

в правой части которого все слагаемые, кроме последнего, равны нулю. Следовательно, неравенство (4.9) имеет вид

$$\left| \frac{f^{(m)}(\bar{x})}{m!} (x - \bar{x})^m \right| \lesssim \bar{\Delta}.$$

Решая его, получаем аналогично (4.10) оценку радиуса интервала неопределенности:

$$\bar{\varepsilon} \approx \left| \frac{m!}{f^{(m)}(\bar{x})} \right|^{1/m} \bar{\Delta}^{1/m}.$$

Эта оценка означает, что для корня кратности  $m$  радиус интервала неопределенности пропорционален  $\bar{\Delta}^{1/m}$ , что свидетельствует о плохой обусловленности задачи вычисления кратных корней. С этой неприятностью мы уже сталкивались при рассмотрении примера 3.9.

Отметим, что  $\bar{\varepsilon}$  не может быть меньше величины  $|x|\varepsilon_m$  — погрешности представления корня  $\bar{x}$  в ЭВМ.

В реальной ситуации оценить величину и даже порядок радиуса интервала неопределенности довольно сложно. Однако знать о его существовании нужно по крайней мере по двум причинам. Во-первых, не имеет смысла ставить задачу о вычислении корня  $\bar{x}$  с точностью  $\varepsilon < \bar{\varepsilon}$ . В условиях неопределенности, вызванных приближенным заданием функции, любое значение  $\bar{x}^* \in (\bar{x} - \bar{\varepsilon}, \bar{x} + \bar{\varepsilon})$  может быть с одной и той же степенью достоверности принято за решение уравнения. Во-вторых, нельзя требовать от алгоритмов отыскания корня получения достоверных результатов после того, как очередное приближение попало в интервал неопределенности или оказалось очень близко от него; в этой ситуации вычисления следует прекратить и считать, что получен максимум действительно возможного.

Для большинства итерационных методов определить этот момент можно, поскольку начиная с него поведение приближений  $x^{(n)}$  становится крайне нерегулярным. Если вдали от интервала неопределенности величина

$$q^{(n)} = |x^{(n)} - x^{(n-1)}| / |x^{(n-1)} - x^{(n-2)}| \quad (4.12)$$

обычно бывает меньше единицы ( $|x^{(n)} - x^{(n-1)}| < |x^{(n-1)} - x^{(n-2)}|$ ), то появление при некотором  $n$  значения  $q^{(n)} > 1$  свидетельствует, скорее всего, о начале "разболтки" — хаотического поведения итерационной последовательности. В этой ситуации вычисления имеет смысл прервать, чтобы выяснить причину явления и принять правильное

решение. Лучшим из полученных приближений к решению следует считать, конечно,  $x^{(n-1)}$ . Использование для контроля вычислений величины (4.12) называют часто *правилом Гарвика*.

### § 4.3. Метод бисекции

**1. Описание метода.** Пусть требуется с заданной точностью  $\varepsilon > 0$  найти корень  $\bar{x}$  уравнения (4.1). Отрезок локализации  $[a, b]$  (т. е. отрезок, содержащий только один корень  $\bar{x}$ ) будем считать заданным. Предположим, что функция  $f$  непрерывна на отрезке  $[a, b]$  и на его концах принимает значения разных знаков, т. е.

$$f(a)f(b) < 0. \quad (4.13)$$

На рис. 4.5 изображен случай, когда  $f(a) < 0$  и  $f(b) > 0$ .

Для дальнейшего будет удобно обозначить отрезок  $[a, b]$  через  $[a^{(0)}, b^{(0)}]$ . Примем за приближенное значение корня середину отрезка — точку  $x^{(0)} = (a^{(0)} + b^{(0)})/2$ . Так как положение корня  $\bar{x}$  на отрезке  $[a^{(0)}, b^{(0)}]$  неизвестно, то можно лишь утверждать, что погрешность этого приближения не превышает половины длины отрезка (рис. 4.5):

$$|x^{(0)} - \bar{x}| \leq (b^{(0)} - a^{(0)})/2.$$

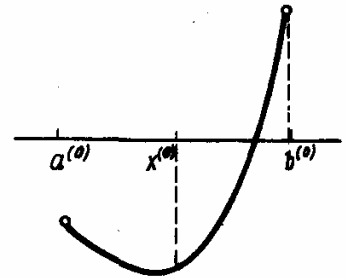


Рис. 4.5

Уменьшить погрешность приближения можно, уточняя отрезок локализации, т. е. заменяя начальный отрезок  $[a^{(0)}, b^{(0)}]$  отрезком  $[a^{(1)}, b^{(1)}]$  меньшей длины. Согласно *методу бисекции* (половинного деления) в качестве  $[a^{(1)}, b^{(1)}]$  берут тот из отрезков  $[a^{(0)}, x^{(0)}]$  и  $[x^{(0)}, b^{(0)}]$ , на концах которого выполняется условие  $f(a^{(1)})f(b^{(1)}) \leq 0$ . Этот отрезок содержит искомый корень. Действительно, если  $f(a^{(1)})f(b^{(1)}) < 0$ , то наличие корня следует из теоремы 4.1; если же  $f(a^{(1)})f(b^{(1)}) = 0$ , то корнем является один из концов отрезка. Середина полученного отрезка  $x^{(1)} = (a^{(1)} + b^{(1)})/2$  дает теперь приближение к корню, оценка погрешности которого составляет

$$|x^{(1)} - \bar{x}| \leq (b^{(1)} - a^{(1)})/2 = (b - a)/2^2.$$

За очередное уточнение отрезка локализации  $[a^{(2)}, b^{(2)}]$  снова берут тот из отрезков  $[a^{(1)}, x^{(1)}]$ ,  $[x^{(1)}, b^{(1)}]$ , на концах которого выполняется условие  $f(a^{(2)})f(b^{(2)}) \leq 0$ .



Опишем очередную  $(n + 1)$ -ю итерацию метода. Пусть отрезок  $[a^{(n)}, b^{(n)}]$  уже найден и вычислены значения  $x^{(n)}, f(a^{(n)}), f(b^{(n)})$ . Тогда производят следующие действия:

1<sup>0</sup>. Вычисляется  $f(x^{(n)})$ .

2<sup>0</sup>. Если  $f(a^{(n)}) f(x^{(n)}) \leq 0$ , то в качестве отрезка локализации  $[a^{(n+1)}, b^{(n+1)}]$  принимается отрезок  $[a^{(n)}, x^{(n)}]$ . В противном случае  $f(x^{(n)}) f(b^{(n)}) < 0$  и за  $[a^{(n+1)}, b^{(n+1)}]$  принимается отрезок  $[x^{(n)}, b^{(n)}]$ .

3<sup>0</sup>. Вычисляется  $x^{(n+1)} = (a^{(n+1)} + b^{(n+1)})/2$ .

Неограниченное продолжение итерационного процесса дает последовательность отрезков  $[a^{(0)}, b^{(0)}], [a^{(1)}, b^{(1)}], \dots, [a^{(n)}, b^{(n)}], \dots$ , содержащих искомый корень. Каждый из них (за исключением начального) получен делением пополам предыдущего отрезка.

**2. Скорость сходимости.** Середина  $n$ -го отрезка — точка  $x^{(n)} = (a^{(n)} + b^{(n)})/2$  дает приближение к корню  $\bar{x}$ , имеющее оценку погрешности

$$|x^{(n)} - \bar{x}| \leq (b^{(n)} - a^{(n)})/2 = (b - a)/2^{n+1}. \quad (4.14)$$

Из этой оценки видно, что метод бисекции сходится со скоростью геометрической прогрессии, знаменатель которой  $q = 1/2$ . По сравнению с другими методами метод бисекции сходится довольно медленно. Однако он очень прост и весьма непритязателен; для его применения достаточно, чтобы выполнялось неравенство (4.13), функция  $f$  была непрерывна и верно определялся ее знак. В тех ситуациях, где не нужна сверхвысокая скорость сходимости (а это часто имеет место при простых инженерных расчетах), этот метод весьма привлекателен.

Заметим, что число итераций, которое требуется при применении метода бисекции для достижения разумной точности  $\varepsilon$ , не может быть очень большим. Например, для уменьшения первоначального отрезка локализации в  $10^6$  раз нужно 19 итераций.

**3. Критерий окончания.** Итерации следует вести до тех пор, пока не будет выполнено неравенство  $b^{(n)} - a^{(n)} < 2\varepsilon$ . При его выполнении в силу оценки (4.14) можно принять  $x^{(n)}$  за приближение к корню с точностью  $\varepsilon$ .

**Пример 4.4.** Найдём методом бисекции с точностью  $\varepsilon = 10^{-2}$  положительный корень уравнения  $4(1 - x^2) - e^x = 0$ .

В примере 4.2 этот корень был локализован на отрезке  $[0, 1]$ , причем  $f(0) > 0, f(1) < 0$ . Положим  $a^{(0)} = 0, b^{(0)} = 1, x^{(0)} = (a^{(0)} + b^{(0)})/2 = 0.5$ .

I и т е р а ц и я. Вычисляем  $f(x^{(0)}) \approx 1.3512$ . Так как  $f(a^{(0)}) f(x^{(0)}) > 0$ , то за очередной отрезок локализации принимаем  $[a^{(1)}, b^{(1)}] = [0.5, 1]$ . Вычисляем  $x^{(1)} = (a^{(1)} + b^{(1)})/2 = 0.75$ .

II и т е р а ц и я. Вычисляем  $f(x^{(1)}) \approx -0.3670$ . Так как  $f(a^{(1)}) f(x^{(1)}) < 0$ , то  $[a^{(2)}, b^{(2)}] = [0.5, 0.75]$  и  $x^{(2)} = (a^{(2)} + b^{(2)})/2 = 0.625$ .

Результаты следующих итераций (с четырьмя цифрами после десятичной точки) приведены в табл. 4.2.

Т а б л и ц а 4.2

Номер итера- ции $k$	$a^{(n)}$	$b^{(n)}$	Знак $f(a^{(n)})$	Знак $f(b^{(n)})$	$x^{(n)}$	$f(x^{(n)})$	$b^{(n)} - a^{(n)}$
0	0.0000	1.0000	+	-	0.5000	1.3513	1.0000
1	0.5000	1.0000	+	-	0.7500	-0.3670	0.5000
2	0.5000	0.7500	+	-	0.6250	0.5693	0.2500
3	0.6250	0.7500	+	-	0.6875	0.1206	0.1250
4	0.6875	0.7500	+	-	0.7187	-0.1182	0.0625
5	0.6875	0.7187	+	-	0.7031	0.0222	0.0312
6	0.7031	0.7187	+	-	0.7109		0.0156

При  $n = 6$  имеем  $b^{(6)} - a^{(6)} \approx 0.0156 < 2 \cdot 10^{-2}$ . Следовательно, заданная точность достигнута и можно принять  $\bar{x} \approx x^{(6)}$ . Окончательно получим  $\bar{x} = 0.71 \pm 0.01$ .

**4. Влияние вычислительной погрешности.** При использовании метода бисекции принципиально важным является правильное определение знака функции  $f$ . В случае, когда  $x^{(n)}$  попадает в интервал неопределенности корня (см. § 4.2), знак вычисленного значения  $f^*(x^{(n)})$  не обязан быть верным, и последующие итерации не имеют смысла. Однако этот метод следует признать очень надежным; он гарантирует точность приближения, примерно равную радиусу интервала неопределенности  $\bar{\epsilon}$ . Как было отмечено в предыдущем параграфе, большего требовать нельзя.

#### § 4.4. Метод простой итерации

**1. Описание метода.** Чтобы применить метод простой итерации для решения нелинейного уравнения (4.1), необходимо преобразовать это уравнение к следующему виду:

$$x = \varphi(x). \quad (4.15)$$

Это преобразование (*приведение уравнения к виду, удобному для итерации*) можно выполнить различными способами; некоторые из них будут указаны ниже. Функцию  $\varphi$  далее будем называть *итерационной функцией*.

Выберем каким-либо образом приближенное значение корня  $x^{(0)}$  и подставим его в правую часть уравнения (4.15). Получим значение  $x^{(1)} = \varphi(x^{(0)})$ . Подставляя теперь  $x^{(1)}$  в правую часть уравнения (4.15), имеем  $x^{(2)} = \varphi(x^{(1)})$ . Продолжая этот процесс неограниченно, получим последовательность приближений к корню, вычисляемых по формуле

$$x^{(n+1)} = \varphi(x^{(n)}), \quad n \geq 0. \quad (4.16)$$

Очевидно, что метод простой итерации — одношаговый (см. § 4.1).

Если существует предел построенной последовательности  $\bar{x} = \lim_{n \rightarrow \infty} x^{(n)}$ , то, переходя к пределу в равенстве (4.16) и предполагая функцию  $\varphi$  непрерывной, получим равенство

$$\bar{x} = \varphi(\bar{x}). \quad (4.17)$$

Это значит, что  $\bar{x}$  — корень уравнения (4.15).

**2. Геометрическая иллюстрация.** Из рис. 4.6 видно, что корень  $\bar{x}$  уравнения (4.15) является абсциссой точки пересечения графиков двух функций:  $y = x$  и  $y = \varphi(x)$ . Возьмем некоторое начальное приближение  $x^{(0)}$ , которому отвечает расположенная на кривой  $y = \varphi(x)$  точка  $M^{(0)}$  с координатами  $(x^{(0)}, x^{(1)})$  (напомним, что  $x^{(1)} = \varphi(x^{(0)})$ ). Соединим точку  $M^{(0)}$  отрезком прямой  $y = x^{(1)}$  с лежащей на прямой  $y = x$  точкой  $N^{(1)}$  с координатами  $(x^{(1)}, x^{(1)})$ . Проведем теперь через точку  $N^{(1)}$  прямую  $x = x^{(1)}$  до пересечения с кривой  $y = \varphi(x)$  в точке  $M^{(1)}$  с координатами  $(x^{(1)}, x^{(2)})$ . Продолжая этот процесс далее, получаем ломаную линию  $M^{(0)}N^{(1)}M^{(1)}N^{(2)}M^{(2)}\dots$ , для которой абсциссы точек  $M^{(n)}$  представляют собой последовательные приближения  $x^{(n)}$  к решению  $\bar{x}$ .

**3. Сходимость метода.** На рис. 4.7, а—г представлена геометрическая иллюстрация поведения итерационного процесса в четырех простейших случаях взаимного расположения прямой  $y = x$  и кривой  $y = \varphi(x)$ .

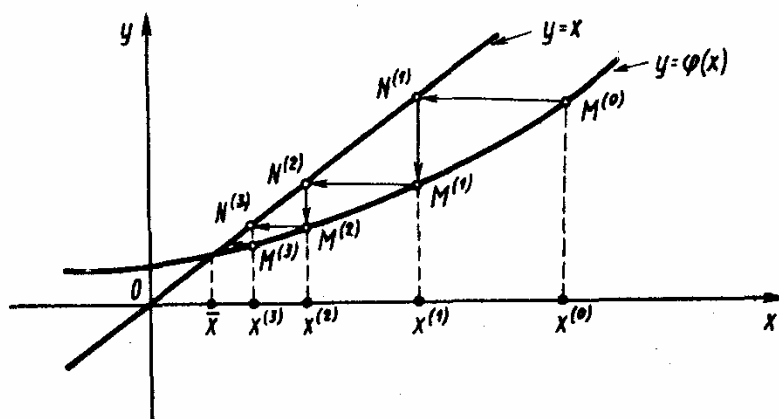


Рис. 4.6

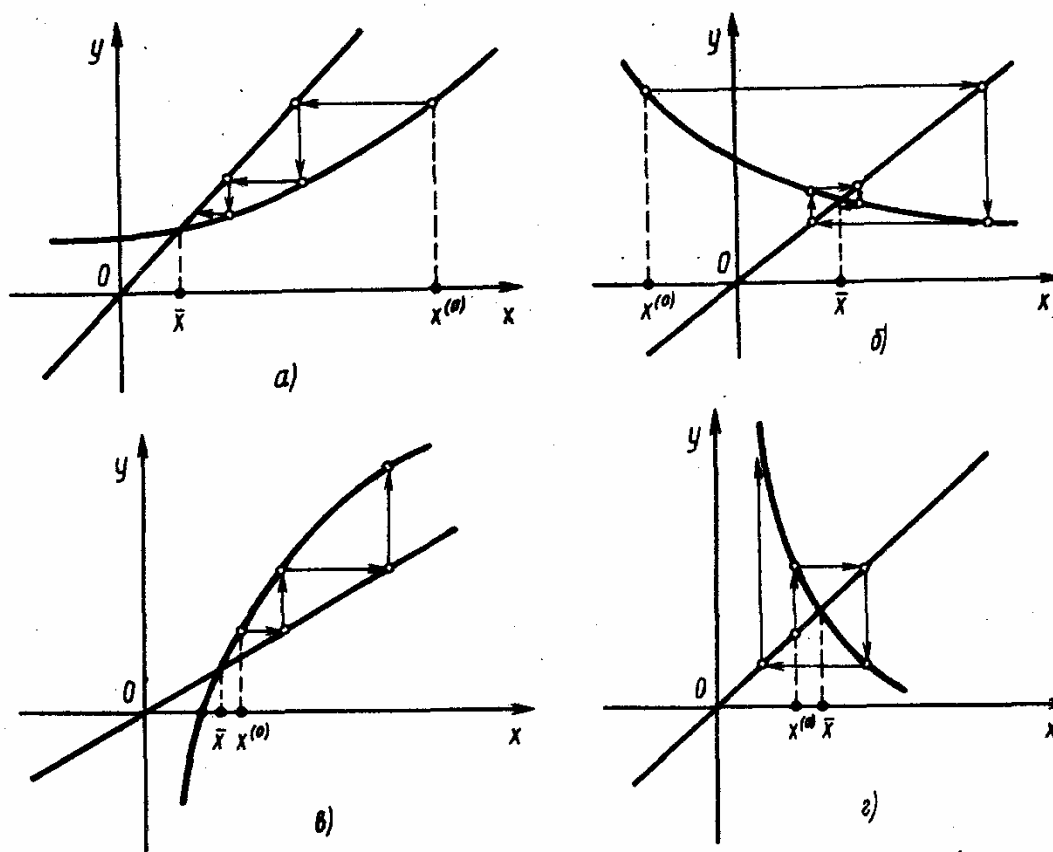


Рис. 4.7

В случаях (а) и (б) метод простой итерации сходится, причем, как нетрудно заметить,— при произвольном начальном приближении. Напротив, в случаях (в) и (г) метод расходится при любом выборе начального приближения. Заметим, что в случаях (а) и (б)  $|\varphi'(x)| < 1$

(как видно из рисунка, модуль тангенса угла наклона кривой  $y = \varphi(x)$  к оси абсцисс меньше единицы), а в случаях (в) и (г), наоборот,  $|\varphi'(x)| > 1$ . Таким образом, можно предположить, что сходимость метода простой итерации связана с выполнением условия  $|\varphi'(x)| < 1$ . Действительно, имеет место следующий результат.

**Теорема 4.2.** Пусть в некоторой  $\sigma$ -окрестности корня  $\bar{x}$  функция  $\varphi$  дифференцируема и удовлетворяет неравенству

$$|\varphi'(x)| \leq q, \quad (4.18)$$

где  $0 \leq q < 1$  — постоянная.

Тогда независимо от выбора начального приближения  $x^{(0)}$  из указанной  $\sigma$ -окрестности корня итерационная последовательность не выходит из этой окрестности, метод сходится со скоростью геометрической прогрессии и справедлива следующая оценка погрешности:

$$|x^{(n)} - \bar{x}| \leq q^n |x^{(0)} - \bar{x}|. \quad (4.19)$$

□ Вычитая из равенства (4.16) равенство (4.17) и используя формулу конечных приращений Лагранжа, получим

$$x^{(n+1)} - \bar{x} = \varphi(x^{(n)}) - \varphi(\bar{x}) = \alpha^{(n+1)} (x^{(n)} - \bar{x}). \quad (4.20)$$

Здесь  $\alpha^{(n+1)} = \varphi'(\xi^{(n)})$ , где  $\xi^{(n)}$  — некоторая точка, расположенная между  $x^{(n)}$  и  $\bar{x}$ . Если  $x^{(n)} \in (\bar{x} - \sigma, \bar{x} + \sigma)$ , то  $|\alpha^{(n+1)}| \leq q$  в силу условия (4.18). Тогда на основании равенства (4.20) получаем

$$|x^{(n+1)} - \bar{x}| \leq q |x^{(n)} - \bar{x}|.$$

Это означает, что метод простой итерации обладает линейной скоростью сходимости и поэтому доказательство теоремы завершается применением леммы 4.1. ■

Оценка погрешности (4.19) является априорной. Она показывает, что метод простой итерации сходится со скоростью геометрической прогрессии, знаменатель которой равен  $q$ . Чем меньше  $q$ , тем выше скорость сходимости. Видна и роль правильного выбора начального приближения: чем меньше погрешность начального приближения, тем меньше итераций потребуется сделать для достижения заданной точности  $\varepsilon$ .

Неравенство (4.19), как правило, не используется для практической оценки погрешности. Одна из причин этого состоит в том, что значение  $\bar{x}$ , входящее в правую часть оценки, неизвестно. Кроме того,

использование неравенства (4.19) приводит к существенно завышенной оценке погрешности.

**4. Критерий окончания.** Выведем апостериорную оценку погрешности, пригодную для практического применения.

**Теорема 4.3.** Пусть выполнены условия теоремы 4.2 и  $x^{(0)} \in (\bar{x} - \sigma, \bar{x} + \sigma)$ . Тогда верна следующая апостериорная оценка погрешности:

$$|x^{(n)} - \bar{x}| \leq \frac{q}{1-q} |x^{(n)} - x^{(n-1)}|, \quad n \geq 1. \quad (4.21)$$

□ В силу равенства (4.20) имеем

$$x^{(n)} - \bar{x} = \alpha^{(n)}(x^{(n-1)} - \bar{x}) = \alpha^{(n)}(x^{(n-1)} - x^{(n)}) + \alpha^{(n)}(x^{(n)} - \bar{x}).$$

Отсюда

$$x^{(n)} - \bar{x} = \frac{\alpha^{(n)}}{1 - \alpha^{(n)}} (x^{(n-1)} - x^{(n)}). \quad (4.22)$$

Взяв модуль от левой и правой частей этого равенства и воспользовавшись неравенством  $\left| \frac{\alpha^{(n)}}{1 - \alpha^{(n)}} \right| \leq \frac{q}{1-q}$ , получим требуемое соотношение (4.21). ■

Если величина  $q$  известна, то неравенство (4.21) дает эффективный метод контроля погрешности и можно сформулировать следующий критерий окончания итерационного процесса. Вычисления следует вести до выполнения неравенства  $\frac{q}{1-q} |x^{(n)} - x^{(n-1)}| < \varepsilon$  или равносильного ему неравенства

$$|x^{(n)} - x^{(n-1)}| < \frac{1-q}{q} \varepsilon. \quad (4.23)$$

Если это условие выполнено, то можно считать, что  $x^{(n)}$  является приближением к  $\bar{x}$  с точностью  $\varepsilon$ .

**Пример 4.5.** Используем метод простой итерации для вычисления положительного корня  $\bar{x}$  уравнения  $4(1 - x^2) - e^x = 0$  с точностью  $\varepsilon = 10^{-4}$ . Результат примера 4.4 дает для корня отрезок локализации  $[a, b] = [0.70, 0.72]$ .

Преобразуем уравнение к виду (4.15), где  $\varphi(x) = \sqrt{1 - e^x/4}$ . Заметим, что  $\varphi'(x) = -e^x/(8\sqrt{1 - e^x/4})$ ,  $\varphi''(x) = -e^x(1 - e^x/8)/(8\sqrt{1 - e^x/4})^3$ . Так как  $\varphi'' < 0$  на  $[a, b]$ , то производная  $\varphi'$  монотонно убывает и  $q = \max_{[a, b]} |\varphi'(x)| = \varphi'(b) \approx 0.37$ . Следовательно, условие сходимости (4.18) выполнено. Возьмем  $x^{(0)} = 0.7$  и будем вести итерации до выполнения критерия (4.23). В табл. 4.3 соответствующие приближения приведены с 10 знаками мантиссы.

Т а б л и ц а 4.3

$n$	$x^{(n)}$	$\frac{q}{1-q}  x^{(n)} - x^{(n-1)} $
0	0.7000000000	
1	0.7046714292	$3 \cdot 10^{-3}$
2	0.7029968319	$1 \cdot 10^{-3}$
3	0.7035984939	$4 \cdot 10^{-4}$
4	0.7033824994	$2 \cdot 10^{-4}$
5	0.7034600632	$5 \cdot 10^{-5}$

Критерий окончания выполняется при  $n = 5$ . После округления значения  $x^{(5)}$  до четырех значащих цифр получим  $\bar{x} = 0.7035 \pm 0.0001$ .

**З а м е ч а н и е.** Часто в практике вычислений вместо критерия (4.23) используется привлекательный своей простотой критерий

$$|x^{(n)} - x^{(n-1)}| < \varepsilon. \quad (4.24)$$

В случае  $0 < q \leq 1/2$  использование критерия (4.24) оправдано. Действительно, здесь  $(1 - q)/q \geq 1$  и поэтому выполнение неравенства (4.24) влечет за собой выполнение неравенства (4.23).

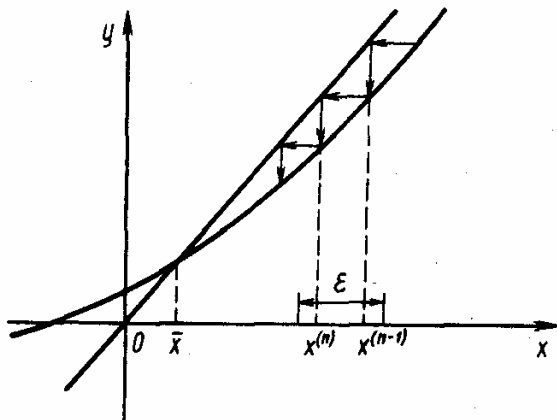


Рис. 4.8

В то же время в случае  $1/2 < q < 1$  использование критерия (4.24) может привести к преждевременному прекращению итераций. Дело в том, что когда величина  $q$  близка к единице, итерационный процесс сходится медленно и расстояние между двумя последовательными приближениями  $x^{(n)}$  и  $x^{(n-1)}$  не характеризует расстояния от  $x^{(n)}$  до решения  $\bar{x}$  (рис. 4.8).

**Пример 4.6.** Пусть метод простой итерации используется для решения уравнения  $x = 0.9999x + 10^{-4}/\sqrt{2}$ . Здесь  $\varphi(x) = 0.9999x + \frac{10^{-4}}{\sqrt{2}}$ ,  $\varphi'(\xi) = 0.9999$

и, следовательно, условие (4.18) сходимости метода выполнено. Для вычислений по формуле (4.16) используем 6-разрядную десятичную ЭВМ. Возьмем  $x^{(0)} = 0.715010$ . Тогда  $x^{(1)} = 0.715009$  и, если доверять критерию (4.24), то следовало бы считать, что решение получено с точностью  $\varepsilon = 10^{-6}$ . Продолжая

вычисления, получим  $x^{(2)} = 0.715008$ ,  $x^{(3)} = 0.715007$ ,  $x^{(4)} = 0.715006$ ,  $x^{(5)} = 0.715005$ ,  $x^{(6)} = 0.715005$ . Дальнейшие итерации теряют смысл. Сколько же верных знаков найдено? Сравнение с точным значением решения  $\bar{x} = \frac{1}{\sqrt{2}} = 0.707106\dots$  показывает, что верными в приближении  $x^{(6)}$  являются

только две значащие цифры. Использование критерия (4.24) в данном случае категорически недопустимо. В дальнейшем мы еще вернемся к обсуждению этого примера.

Использование критерия (4.23) предполагает знание величины  $q$ , входящей в условие (4.18). Однако далеко не всегда эта величина известна, либо может быть легко вычислена. В тех же случаях, когда удастся оценить  $q$ , эта оценка оказывается довольно грубой.

Исключим из критерия окончания итераций величину  $q$ . Заметим, что в малой окрестности корня величина производной  $\varphi'$  практически постоянна:  $\varphi'(x) \approx \varphi'(\bar{x})$ . Поэтому в равенстве (4.22) величину  $\alpha^{(n)} = \varphi'(\xi^{(n-1)})$  можно приближенно заменить на  $\varphi'(\bar{x})$ . Далее в силу равенства

$$x^{(n)} - x^{(n-1)} = \varphi(x^{(n-1)}) - \varphi(x^{(n-2)}) = \varphi'(\tilde{\xi}^{(n)})(x^{(n-1)} - x^{(n-2)}),$$

где  $\tilde{\xi}^{(n)}$  — промежуточная между  $x^{(n-1)}$  и  $x^{(n-2)}$  точка, имеем  $\tilde{\alpha}^{(n)} = (x^{(n)} - x^{(n-1)}) / (x^{(n-1)} - x^{(n-2)}) = \varphi'(\tilde{\xi}^{(n)}) \approx \varphi'(\bar{x})$ . Таким образом, в равенстве (4.22) можно положить  $\alpha^{(n)} \approx \tilde{\alpha}^{(n)}$  и поэтому при определенных условиях можно использовать следующий практический критерий окончания итерационного процесса:

$$|x^{(n)} - x^{(n-1)}| \lesssim \left| \frac{1 - \tilde{\alpha}^{(n)}}{\tilde{\alpha}^{(n)}} \right| \varepsilon.$$

**5. Дополнительные сведения о характере сходимости.** В случае, когда производная  $\varphi'$  знакопостоянна на отрезке локализации, итерационная последовательность обладает некоторыми полезными дополнительными свойствами. Заметим, что при  $\varphi'(\bar{x}) \neq 0$  в достаточно малой окрестности корня знак производной  $\varphi'(x)$  действительно постоянен.

**Т е о р е м а 4.4.** Пусть  $[a, b]$  — отрезок локализации корня уравнения (4.15). Предположим, что на этом отрезке функция  $\varphi$  непрерывно дифференцируема, а ее производная  $\varphi'(x)$  знакопостоянна и удовлетворяет неравенству (4.18) при  $0 < q < 1$ . Пусть  $x^{(0)} \in [a, b]$  — произ-



вольное начальное приближение и в случае  $\varphi' < 0$  выполнено дополнительное условие  $x^{(1)} = \varphi(x^{(0)}) \in [a, b]$  (первое приближение не выходит за пределы отрезка локализации).

Тогда итерационная последовательность не выходит за пределы отрезка  $[a, b]$ , метод простой итерации сходится и верны оценки погрешности (4.19), (4.21).

Кроме того, справедливы следующие свойства:

1°. Если  $\varphi' > 0$  на  $[a, b]$ , то  $x^{(n)}$  сходится к  $\bar{x}$ , монотонно возрастая в случае  $a \leq x^{(0)} < \bar{x}$ , и монотонно убывая в случае  $\bar{x} < x^{(0)} \leq b$ .

2°. Если  $\varphi' < 0$  на  $[a, b]$ , то сходимость  $x^{(n)}$  к  $\bar{x}$  носит колебательный характер, т. е. при всех  $n \geq 0$  значения  $x^{(n)}$  и  $x^{(n+1)}$  расположены по разные стороны от  $\bar{x}$ , причем последовательности приближений с четными и нечетными номерами сходятся к  $\bar{x}$  монотонно. В этом случае верна апостериорная оценка погрешности

$$|x^{(n)} - \bar{x}| \leq |x^{(n)} - x^{(n-1)}|, \quad n \geq 1 \quad (4.25)$$

и справедлив критерий (4.24) окончания итерационного процесса.

Мы не будем приводить здесь полное доказательство теоремы. Оно основано на использовании равенства (4.20), установленного при доказательстве теоремы 4.2. Докажем только справедливость свойств 1° и 2°.

□ Если  $0 < \varphi' \leq q$ , то знаки величин  $x^{(n)} - \bar{x}$  и  $x^{(n-1)} - \bar{x}$  совпадают, в то время как  $|x^{(n)} - \bar{x}| \leq q|x^{(n-1)} - \bar{x}|$ . Следовательно, последовательность монотонно приближается к  $\bar{x}$  с той стороны, где лежит  $x^{(0)}$ . Если же  $-q < \varphi' < 0$ , то из равенства (4.20) следует, что знаки величин  $x^{(n)} - \bar{x}$  и  $x^{(n-1)} - \bar{x}$  различны. Это подтверждает колебательный характер сходимости. ■

**З а м е ч а н и е.** Монотонный и колебательный характер сходимости итерационной последовательности, указанные в теореме 4.4, иллюстрируют соответственно рис. 4.7, а и 4.7, б.

**6. Приведение уравнения к виду, удобному для итераций.** Ключевой момент в применении метода простой итерации — эквивалентное преобразование уравнения (4.1) к виду (4.15). Конечно, такое преобразование имеет смысл только тогда, когда оказывается выполненным условие (4.18) при  $0 < q < 1$ . Укажем один из простых способов такого преобразования.

Предположим, что производная  $f'$  на отрезке  $[a, b]$  непрерывна и положительна. Тогда существуют положительные постоянные  $m$  и  $M$  такие, что  $0 < m \leq f'(x) \leq M$ ,  $x \in [a, b]$ . Приведем уравнение (4.1) к виду

$$x = x - \alpha f(x), \quad (4.26)$$

где  $\alpha > 0$ . В этом случае итерационная функция  $\varphi$  имеет вид  $\varphi(x) = x - \alpha f(x)$ . Как выбрать  $\alpha$ , чтобы выполнялось условие (4.18), причем  $q$  было бы по возможности минимальным?

Заметим, что  $1 - \alpha M \leq \varphi'(x) = 1 - \alpha f'(x) \leq 1 - \alpha m$  и поэтому  $|\varphi'(x)| \leq q(\alpha) = \max \{|1 - \alpha M|, |1 - \alpha m|\}$ . Для того чтобы было выполнено неравенство  $q(\alpha) < 1$ , достаточно взять любое  $\alpha \in (0, 2/M)$ . Конкретный выбор параметра  $\alpha$  зависит от наличия информации о числах  $m$  и  $M$ . Если известны обе эти величины, то лучшим является выбор  $\alpha = \alpha_0 = 2/(M + m)$ . В этом случае  $q(\alpha_0) = (M - m)/(M + m)$ . Если же известно только  $M$ , то можно положить  $\alpha = \alpha_1 = \frac{1}{M}$ . В этом случае  $q(\alpha_1) = 1 - \frac{m}{M}$ . Кроме того, при  $\alpha = \alpha_1$  производная  $\varphi'(x)$  неотрицательна, и в силу теоремы 4.3 сходимость является монотонной.

**З а м е ч а н и е.** Случай, когда производная  $f'$  отрицательна, сводится к рассмотренному выше умножением уравнения  $f(x) = 0$  на  $-1$ .

**Пример 4.7.** Для решения задачи, поставленной в примере 4.5, можно воспользоваться преобразованием уравнения (4.4) к виду (4.26). Будем считать известным, что  $x \in [0.70, 0.72]$ . Так как на отрезке локализации выполнено условие  $(4(1 - x^2) - e^x)' = -8x - e^x < 0$ , то перепишем уравнение в виде  $f_1(x) = 0$ , где  $f_1(x) = e^x - 4(1 - x^2)$ . Тогда  $f_1'(x) = e^x + 8x$  и для  $x \in [0.70, 0.72]$  верны оценки  $0 < m = f_1'(0.70) \leq f_1'(x) \leq f_1'(0.72) = M$ . Выберем

в уравнении (4.26)  $\alpha = \frac{2}{m + M}$ , возьмем  $x^{(0)} = 0.7$  и будем вести итерации по формуле  $x^{(n+1)} = x^{(n)} - \alpha[e^{x^{(n)}} - 4(1 - x^{(n)})^2]$ . Выбранному  $\alpha$  соответствует  $q = \frac{M - m}{M + m} \approx 0.013$  и поэтому сходимость должна быть более быстрой, чем в примере 4.6. Действительно, уже первая итерация дает  $x^{(1)} = 0.7034025118$ , и так как  $\frac{q}{1 - q} \cdot |x^{(1)} - x^{(0)}| \approx 5 \cdot 10^{-5}$ , то итерации следует прекратить и считать  $\bar{x} = 0.7034 \pm 0.0001$ .

## § 4.5. Обусловленность метода простой итерации

В § 4.4 метод простой итерации был рассмотрен при идеальном предположении о возможности точного вычисления значений функции  $\varphi(x)$ . В действительности же вычисления на ЭВМ дают приближенные значения  $\varphi^*(x)$ . Поэтому вместо последовательности  $x^{(n)}$ , удовлетворяющей равенству  $x^{(n+1)} = \varphi(x^{(n)})$ , получается последовательность  $\tilde{x}^{(n)}$ , для которой

$$\tilde{x}^{(n+1)} = \varphi^*(\tilde{x}^{(n)}). \quad (4.27)$$

Известно, что метод простой итерации и многие другие итерационные методы устойчивы к ошибке, допущенной на одной из итераций. Такая ошибка эквивалентна некоторому ухудшению очередного приближения; если она не вывела приближение за пределы области сходимости, то итерационная последовательность по-прежнему будет сходиться к решению  $\bar{x}$ , а внесенная ошибка — затухать. Поэтому о таких итерационных методах говорят, что они обладают *свойством самоисправляемости*.

Однако погрешности допускаются не на одной, а на всех итерациях и совокупное их влияние несколько иное.

**1. Обусловленность задачи.** Прежде чем сформулировать результат о поведении метода простой итерации при наличии погрешности в вычислении функции  $\varphi$ , отметим, что преобразование уравнения  $f(x) = 0$  к виду  $x = \varphi(x)$  изменяет обусловленность задачи. Запишем это уравнение в виде  $\tilde{f}(x) = 0$ , где  $\tilde{f}(x) = x - \varphi(x)$ , и воспользуемся результатами § 4.2. Заметим, что  $\bar{\Delta}(\tilde{f}^*) = \bar{\Delta}(\varphi^*)$ , поскольку в действительности приближенно вычисляется только функция  $\varphi$ . Поэтому оценка (4.11) в данном случае выглядит так:

$$\bar{\Delta}(\bar{x}^*) \lesssim \nu \bar{\Delta}(\varphi^*). \quad (4.28)$$

Здесь  $\nu = 1/|1 - \varphi'(\bar{x})|$  — абсолютное число обусловленности корня  $\bar{x}$ . Грубо оценивая при выполнении условия  $|\varphi'| \leq q < 1$  величину  $\nu$  числом  $\bar{\nu} = \frac{1}{1 - q}$ , приходим к оценке

$$\bar{\Delta}(\bar{x}^*) \lesssim \frac{\bar{\Delta}(\varphi^*)}{1 - q}. \quad (4.29)$$

В случае, когда  $\varphi' \leq 0$  или  $\varphi' \approx 0$ , ее можно уточнить. Действительно, как нетрудно установить,  $\nu \lesssim 1$ , если  $\varphi' \lesssim 0$ ; следовательно,

$$\bar{\Delta}(\bar{x}^*) \lesssim \bar{\Delta}(\varphi^*). \quad (4.30)$$

Заметим, что в оценках (4.28)–(4.30) величины  $\bar{\Delta}(\bar{x}^*)$  и  $\bar{\Delta}(\varphi^*)$  можно заменить на  $\bar{\delta}(\bar{x}^*)$  и  $\bar{\delta}(\varphi^*)$ . Чтобы убедиться в этом, достаточно разделить левую и правую части оценок на величины  $|\bar{x}|$  и  $|\varphi(\bar{x})|$ , которые равны между собой. Например, оценка (4.28) преобразуется к виду

$$\bar{\delta}(\bar{x}^*) \lesssim \nu \bar{\delta}(\varphi^*) \quad (4.31)$$

и, следовательно, абсолютное и относительное числа обусловленности здесь совпадают.

Сделаем некоторые выводы. Задача вычисления корня  $\bar{x}$  уравнения  $x = \varphi(x)$  плохо обусловлена, если  $\varphi'(\bar{x}) \approx 1$ . В этом случае следует ожидать, что количество верных цифр корня  $\bar{x}$  по сравнению с количеством верных цифр в вычисляемых значения  $\varphi^*(x)$  должно быть меньше примерно на  $N = \lg \nu$  цифр. Для радиуса интервала неопределенности  $\bar{\varepsilon} \approx \nu \bar{\Delta}(\varphi^*)$  корня  $\bar{x}$  в случае  $|\varphi'| \leq q < 1$  справедлива оценка  $\bar{\varepsilon} \leq \bar{\varepsilon}^* = \frac{\bar{\Delta}(\varphi^*)}{1 - q}$ . В случае, когда  $-1 < \varphi' \lesssim 0$ , уточненная оценка такова:  $\bar{\varepsilon} \lesssim \bar{\varepsilon}^* = \bar{\Delta}(\varphi^*)$ ; здесь потери верных цифр быть не должно.

**Пример 4.9.** Для уравнения  $x = \varphi(x)$  при  $\varphi(x) = 0.9999x + 10^{-4}/\sqrt{2}$  имеем  $\varphi'(x) = 0.9999$  и, следовательно,  $\nu = 10^4$ . Поэтому при решении этого уравнения методом простой итерации на ЭВМ будет потеряно примерно четыре значащих цифры. Вычисления на 6-разрядной десятичной ЭВМ (или на близкой ей по точности ЭВМ типа IBM PC) могут дать в таком случае всего лишь две верные значащие цифры. Это вполне согласуется с результатом, полученным в примере 4.6.

**2. Чувствительность метода простых итераций к погрешности вычислений.** Сформулируем основной результат данного параграфа.

**Теорема 4.5.** Пусть выполнены условия теоремы 4.2 и для всех  $x \in (\bar{x} - \sigma, \bar{x} + \sigma)$  имеет место неравенство  $|\varphi(x) - \varphi(x^*)| \leq \bar{\Delta}(\varphi^*)$ .

Предположим также, что  $\bar{\varepsilon}^* = \frac{\bar{\Delta}(\varphi^*)}{1-q} < \sigma$  (т. е. величина  $\bar{\Delta}(\varphi^*)$  достаточно мала).

Если вычисления по формулам (4.16) и (4.27) начинаются с одного начального приближения  $x^{(0)} = \tilde{x}^{(0)} \in (\bar{x} - \sigma_1, \bar{x} + \sigma_1)$  (где  $\sigma_1 = \min \left\{ \sigma, \frac{\sigma - \bar{\varepsilon}^*}{q} \right\}$ ), то последовательность  $\tilde{x}^{(n)}$  не выходит за пределы  $\sigma$ -окрестности корня  $\bar{x}$  и для всех  $n \geq 1$  справедливы следующие оценки погрешности:

$$|\tilde{x}^{(n)} - x^{(n)}| \leq \bar{\varepsilon}^*, \quad (4.32)$$

$$|\tilde{x}^{(n)} - \bar{x}| \leq q^n |\tilde{x}^{(0)} - \bar{x}| + \bar{\varepsilon}^*, \quad (4.33)$$

$$|\tilde{x}^{(n)} - \bar{x}| \leq C |\tilde{x}^{(n)} - \tilde{x}^{(n-1)}| + \bar{\varepsilon}^*. \quad (4.34)$$

Здесь  $C = \frac{q}{1-q}$ .

**З а м е ч а н и е 1.** В случае  $\varphi' \lesssim 0$  в неравенствах (4.32)–(4.34)

можно положить  $\bar{\varepsilon}^* \approx \bar{\Delta}(\varphi^*)$ ,  $C \approx 1$ .

**З а м е ч а н и е 2.** При достаточно больших  $n$  в оценках (4.32)–(4.34) величину  $\bar{\varepsilon}^*$  можно считать приближенно равной радиусу

$$\text{интервала неопределенности } \bar{\varepsilon} = \frac{\bar{\Delta}(\varphi^*)}{1 - \varphi'(\bar{x})}.$$

□ Докажем по индукции, что для всех  $n \geq 0$  справедливы неравенства (4.32), (4.33) и  $\tilde{x}^{(n)} \in (\bar{x} - \sigma, \bar{x} + \sigma)$ . Очевидно, что при  $n = 0$  это верно.

Предположим, что доказываемое утверждение справедливо при некотором  $n \geq 0$ . Вычитая из равенства (4.27) равенство (4.16), получаем

$$\tilde{x}^{(n+1)} - x^{(n+1)} = \varphi'(\tilde{\xi}^{(n)})(\tilde{x}^{(n)} - x^{(n)}) + \tilde{\Delta}^{(n)}, \quad \tilde{\xi}^{(n)} \in (\bar{x} - \sigma, \bar{x} + \sigma),$$

где  $\tilde{\Delta}^{(n)} = \varphi^*(\tilde{x}^{(n)}) - \varphi(\tilde{x}^{(n)})$ ,  $|\tilde{\Delta}^{(n)}| \leq \bar{\Delta}(\varphi^*)$ . Как следствие полученного равенства и сделанных предположений, имеем

$$|\tilde{x}^{(n+1)} - x^{(n+1)}| \leq q |\tilde{x}^{(n)} - x^{(n)}| + |\tilde{\Delta}^{(n)}| \leq q \bar{\varepsilon}^* + \bar{\Delta}(\varphi^*) = \bar{\varepsilon}^*.$$

Объединяя эту оценку с оценкой (4.19), получаем

$$|\tilde{x}^{(n+1)} - \bar{x}| \leq q^{n+1} |\tilde{x}^{(0)} - \bar{x}| + \bar{\varepsilon}^*.$$

Поэтому

$$|\tilde{x}^{(n+1)} - \bar{x}| < q\sigma_1 + \bar{\varepsilon}^* \leq \frac{q(\sigma - \bar{\varepsilon}^*)}{q} + \bar{\varepsilon}^* = \sigma.$$

Нужное утверждение доказано для номера, равного  $n + 1$ , а следовательно, и для всех  $n \geq 0$ .

Вычитая из равенства (4.27) равенство (4.17), получаем

$$\begin{aligned} \tilde{x}^{(n+1)} - \bar{x} &= \alpha^{(n)} (\tilde{x}^{(n)} - \bar{x}) + \tilde{\Delta}^{(n)}, \quad \alpha^{(n)} = \varphi'(\xi^{(n)}), \\ \xi^{(n)} &\in (\bar{x} - \sigma, \bar{x} + \sigma). \end{aligned}$$

Таким образом,

$$\tilde{x}^{(n+1)} - \bar{x} = \frac{\alpha^{(n)}}{1 - \alpha^{(n)}} (\tilde{x}^{(n)} - \tilde{x}^{(n+1)}) + \frac{\tilde{\Delta}^{(n)}}{1 - \alpha^{(n)}}.$$

Из полученного равенства вытекает оценка (4.34). ■

Итак, итерационный процесс не ухудшает обусловленность корня  $\bar{x}$ . Как оказывается, гарантированная точность метода простой итерации ограничена снизу величиной, примерно совпадающей с радиусом  $\bar{\varepsilon}$  интервала неопределенности. Критерий (4.23) окончания итераций применим, если  $\bar{\varepsilon}^* \ll \varepsilon$ .

Входящую в соотношения (4.29), (4.30) величину  $\bar{\Delta}(\varphi^*)$  в общем случае оценить сверху достаточно сложно. Оценка снизу очевидна:  $\bar{\Delta}(\varphi^*) \gtrsim |\bar{x}| \varepsilon_M$ . В благоприятной ситуации, когда вычисления ведутся по простым формулам, можно надеяться на то, что  $\bar{\Delta}(\varphi^*)$  окажется величиной порядка  $|\bar{x}| \varepsilon_M$ .

#### § 4.6. Метод Ньютона

Знаменитый метод Ньютона является одним из наиболее эффективных методов решения самых разных нелинейных задач. Расчетную формулу метода можно получить, используя различные подходы. Рассмотрим два из них.

**1. Метод касательных.** Выведем расчетную формулу метода для решения нелинейного уравнения (4.1) из простых геометрических соображений. Соответствующая иллюстрация приведена на рис. 4.9.

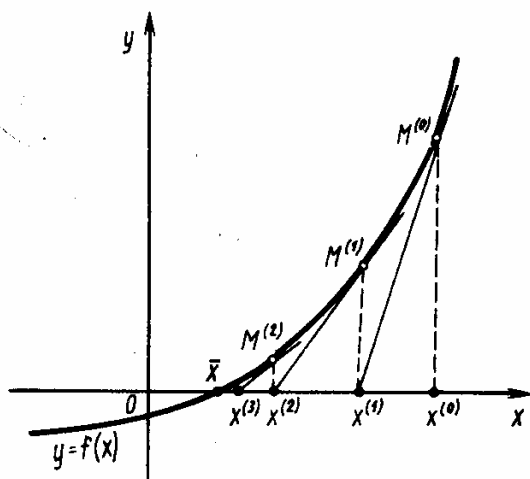


Рис. 4.9

Пусть  $x^{(0)}$  — заданное начальное приближение к корню  $\bar{x}$ . В точке  $M^{(0)}$  с координатами  $(x^{(0)}, f(x^{(0)}))$  проведем касательную к графику функции  $y = f(x)$  и за новое приближение  $x^{(1)}$  примем абсциссу точки пересечения этой касательной с осью  $Ox$ . Аналогично, за приближение  $x^{(2)}$  примем абсциссу точки пересечения с осью  $Ox$  касательной, проведенной к графику в точке  $M^{(1)}$  с координатами  $(x^{(1)}, f(x^{(1)}))$ . Продолжая этот процесс далее, получим последовательность  $x^{(0)}, x^{(1)}, x^{(2)}, \dots, x^{(n)}, \dots$  приближений к корню  $\bar{x}$ .

Напомним, что уравнение касательной, проведенной к графику функции  $y = f(x)$  в точке  $(x^{(n)}, f(x^{(n)}))$ , имеет вид

$$y = f(x^{(n)}) + f'(x^{(n)})(x - x^{(n)}). \quad (4.35)$$

Полагая в равенстве (4.35)  $y = 0$ , замечаем, что при выполнении условия  $f'(x^{(n)}) \neq 0$  абсцисса  $x^{(n+1)}$  точки пересечения касательной с осью  $Ox$  удовлетворяет равенству

$$0 = f(x^{(n)}) + f'(x^{(n)})(x^{(n+1)} - x^{(n)}). \quad (4.36)$$

Выражая из него  $x^{(n+1)}$ , получаем расчетную формулу метода Ньютона:

$$x^{(n+1)} = x^{(n)} - \frac{f(x^{(n)})}{f'(x^{(n)})}, \quad n \geq 0. \quad (4.37)$$

Благодаря такой геометрической интерпретации этот метод часто называют *методом касательных*.

**2. Метод линеаризации.** С более общих позиций метод Ньютона можно рассматривать как итерационный метод, использующий специальную линеаризацию задачи и позволяющий свести решение исходного нелинейного уравнения к решению последовательности линейных уравнений.

Пусть приближение  $x^{(n)}$  уже получено. Представим функцию в окрестности точки  $x^{(n)}$  по формуле Тейлора:

$$f(x) = f(x^{(n)}) + f'(x^{(n)})(x - x^{(n)}) + \frac{f''(\xi)}{2}(x - x^{(n)})^2. \quad (4.38)$$

Здесь  $\xi$  — некоторая точка, расположенная между  $x$  и  $x^{(n)}$ . Заменяя в уравнении  $f(x) = 0$  функцию  $f(x)$  главной линейной частью разложения (4.38), получим линейное уравнение

$$f(x^{(n)}) + f'(x^{(n)})(x - x^{(n)}) = 0. \quad (4.39)$$

Принимая решение уравнения (4.39) за новое приближение  $x^{(n+1)}$ , приходим к формуле (4.37).

### 3. Основная теорема о сходимости метода Ньютона.

**Теорема 4.6.** Пусть  $\bar{x}$  — простой корень уравнения  $f(x) = 0$ , в некоторой окрестности которого функция  $f$  дважды непрерывно дифференцируема. Тогда найдется такая малая  $\sigma$ -окрестность корня  $\bar{x}$ , что при произвольном выборе начального приближения  $x^{(0)}$  из этой окрестности итерационная последовательность метода Ньютона не выходит за пределы окрестности и справедлива оценка

$$|x^{(n+1)} - \bar{x}| \leq C |x^{(n)} - \bar{x}|^2, \quad n \geq 0, \quad (4.40)$$

где  $C = \sigma^{-1}$ , означающая, что метод сходится с квадратичной скоростью.

Следствием оценки (4.40) является априорная оценка

$$|x^{(n)} - \bar{x}| \leq \sigma q^{2^n}, \quad n \geq 0, \quad (4.41)$$

в которой  $q = \sigma^{-1} |x^{(0)} - \bar{x}|$ .

□ Так как  $f'(\bar{x}) \neq 0$  (по определению простого корня), то в силу непрерывности функций  $f'$  и  $f''$  найдется  $\delta_0$ -окрестность корня, в которой при некоторых постоянных  $\alpha$  и  $\beta$  выполнены неравенства  $0 < \alpha \leq |f'(x)|$ ,  $|f''(x)| \leq \beta$ .

Пусть  $x^{(n)} \in (\bar{x} - \sigma, \bar{x} + \sigma)$ , где  $\sigma = \min \{\delta_0, \frac{2\alpha}{\beta}\}$ . Подставляя  $x = \bar{x}$  в (4.38), получим равенство

$$0 = f(x^{(n)}) + f'(x^{(n)})(\bar{x} - x^{(n)}) + \frac{f''(\xi)(\bar{x} - x^{(n)})^2}{2},$$

в котором  $\xi \in (\bar{x} - \sigma, \bar{x} + \sigma)$ . Вычитая из него равенство (4.36), имеем



$$f'(x^{(n)})(x^{(n+1)} - \bar{x}) = \frac{f''(\xi)(\bar{x} - x^{(n)})^2}{2}.$$

Тогда, приравняв модули обеих частей этого равенства и используя условия ограниченности  $|f'(x)|$  и  $|f''(x)|$ , приходим к неравенству  $\alpha|x^{(n+1)} - \bar{x}| \leq \frac{\beta}{2}|x^{(n)} - \bar{x}|^2$ , откуда следует справедливость оценки (4.40). Доказательство теоремы завершается применением леммы 4.2. ■

Таким образом, при выборе начального приближения из достаточно малой окрестности корня метод Ньютона сходится квадратично. Это означает, грубо говоря, что на каждой итерации число верных цифр приближения примерно удваивается.

Приведенные в теореме 4.6 оценки погрешности являются априорными (см. § 3.3) и их использование в практике вычислений для количественной оценки погрешности неэффективно или чаще всего невозможно.

**4. Критерий окончания.** На практике предпочтительнее использование простой апостериорной оценки

$$|x^{(n)} - \bar{x}| \leq |x^{(n)} - x^{(n-1)}|, \quad (4.42)$$

справедливость которой обосновывается следующим утверждением.

**Теорема 4.7.** Пусть выполнены условия теоремы 4.6 и  $x^{(0)} \in (\bar{x} - \frac{\sigma}{2}, \bar{x} + \frac{\sigma}{2})$ . Тогда для всех  $n \geq 1$  верна оценка (4.42).

□ Из оценки (4.41) следует, что  $|x^{(n-1)} - \bar{x}| \leq \sigma q^{2^{n-1}} \leq \sigma q = |x^{(0)} - \bar{x}| < \frac{\sigma}{2}$ . Поэтому, применяя неравенство (4.40), получим цепочку неравенств  $2|x^{(n)} - \bar{x}| \leq 2\sigma^{-1}|x^{(n-1)} - \bar{x}|^2 \leq |x^{(n-1)} - \bar{x}| \leq |x^{(n-1)} - x^{(n)}| + |x^{(n)} - \bar{x}|$ , из которой вытекает оценка (4.42). ■

Наличие оценки (4.42) позволяет сформулировать следующий практический критерий окончания итераций метода Ньютона. При заданной точности  $\varepsilon > 0$  вычисления нужно вести до тех пор, пока не окажется выполненным неравенство

$$|x^{(n)} - x^{(n-1)}| < \varepsilon. \quad (4.43)$$

**Пример 4.8.** Используя метод Ньютона, найдем с точностью  $\varepsilon = 10^{-6}$  положительный корень уравнения  $4(1 - x^2) - e^x = 0$ .

В примере 4.2 корень был локализован на отрезке  $[0, 1]$ . Для  $f(x) =$

$= 4(1 - x^2) - e^x$  имеем  $f'(x) = -8x - e^x$ . Очевидно, что  $f'(\bar{x}) \neq 0$ , т. е.  $\bar{x}$  — простой корень. Возьмем начальное приближение  $x^{(0)} = 0.5$  и будем выполнять итерации метода Ньютона по формуле

$$x^{(n+1)} = x^{(n)} + \frac{4(1 - (x^{(n)})^2) - e^{x^{(n)}}}{8x^{(n)} + e^{x^{(n)}}}.$$

Результаты первых итераций с 10 знаками мантиссы приведены в табл. 4.4.

Т а б л и ц а 4.4

$n$	$x^{(n)}$	$ x^{(n)} - x^{(n-1)} $
0	0.5000000000	
1	0.7392185177	$2.4 \cdot 10^{-1}$
2	0.7042444088	$3.5 \cdot 10^{-2}$
3	0.7034399951	$8.0 \cdot 10^{-4}$
4	0.7034395712	$4.3 \cdot 10^{-7}$

При  $n = 4$  вычисления следует прекратить и после округления получим  $\bar{x} = 0.703440 \pm 0.000001$ .

Сравнение результатов итераций со значением  $\bar{x}$  показывает, что приближения  $x^{(1)}$ ,  $x^{(2)}$ ,  $x^{(3)}$  содержат 1, 3, 6 верных значащих цифр соответственно. Можно показать, что приближение  $x^{(4)}$  содержит 10 верных цифр. Это подтверждает отмеченный ранее общий факт: при каждой итерации метода Ньютона число верных значащих цифр примерно удваивается.

**Пример 4.9.** Используя метод Ньютона, укажем итерационный процесс вычисления  $\sqrt[p]{a}$ , где  $a > 0$ ,  $p$  — натуральное число.

По определению,  $x = \sqrt[p]{a}$  — это неотрицательная величина, удовлетворяющая равенству  $x^p = a$ . Таким образом, задача сводится к вычислению положительного корня уравнения  $f(x) = 0$ , где  $f(x) = x^p - a$ . Итерационная формула метода Ньютона примет вид

$$x^{(n+1)} = x^{(n)} - \frac{(x^{(n)})^p - a}{p(x^{(n)})^{p-1}} = \frac{p-1}{p} x^{(n)} + \frac{a}{p(x^{(n)})^{p-1}}. \quad (4.44)$$

При  $p = 2$  эта формула уже была получена в примере 3.17.

**5. Связь с методом простой итерации.** Метод Ньютона можно рассматривать как один из вариантов метода простой итерации, связанный со специальным преобразованием уравнения  $f(x) = 0$  к виду

$$x = \varphi_N(x), \quad (4.45)$$

где  $\varphi_N(x) = x - f(x)/f'(x)$ . В самом деле, итерационная формула метода простой итерации  $x^{(n+1)} = \varphi_N(x^{(n)})$  совпадает с формулой (4.37).

Исходя из этого с учетом оценки (4.19), можно было бы сделать вывод о том, что метод Ньютона сходится только линейно. Однако заметим, что  $\varphi'_N(x) = f(x) \frac{f''(x)}{(f'(x))^2}$ . Так как  $f(\bar{x}) = 0$ , то  $\varphi'_N(\bar{x}) = 0$  и величина  $\alpha^{(n+1)} = |\varphi'(\xi^{(n)})|$ , определяющая в силу равенства (4.20) коэффициент сжатия ошибки, стремится к нулю при  $n \rightarrow \infty$ . Скорость сходимости возрастает по мере приближения к корню, отсюда и ее сверхлинейный характер.

В качестве аналога теоремы 4.4 для метода Ньютона приведем следующий результат.

**Теорема 4.8.** Пусть  $[a, b]$  — отрезок локализации простого корня  $\bar{x}$  уравнения (4.1). Предположим, что на этом отрезке функция  $f$  дважды непрерывно дифференцируема, а ее производные  $f'(x)$  и  $f''(x)$  знакопостоянны. Пусть  $x^{(0)} \in [a, b]$  — произвольное начальное приближение, и в случае  $f(x^{(0)}) f''(x^{(0)}) < 0$  выполнено дополнительное условие  $x^{(1)} \in [a, b]$  (первое приближение не выходит за пределы отрезка локализации).

Тогда начиная с  $n = 1$  итерационная последовательность метода Ньютона  $x^{(n)}$  сходится к  $\bar{x}$  монотонно с той стороны отрезка  $[a, b]$ , где  $f(x) f''(x) > 0$ .

Иллюстрацией монотонного характера сходимости может служить рис. 4.9.

**С л е д с т в и е.** Пусть уравнение  $f(x)$  имеет корень  $\bar{x}$ , функция  $f(x)$  дважды непрерывно дифференцируема на всей числовой оси, а ее производные  $f'$  и  $f''$  знакопостоянны. Тогда метод Ньютона сходится при любом начальном приближении  $x^{(0)}$  (т. е. является глобально сходящимся), причем начиная с  $n = 1$  последовательность сходится монотонно с той стороны от корня, где  $f(x) f''(x) > 0$ .

**6. Трудности использования.** Простота, логическая стройность и высокая скорость сходимости делают метод Ньютона чрезвычайно привлекательным. Однако для его практического применения нужно преодолеть две существенные трудности. Одна из них состоит в необходимости вычисления производной  $f'(x)$ . Часто бывает невозможно найти аналитическое выражение для  $f'(x)$ , а определить приближенное значение с высокой точностью очень трудно. Иногда вычисление

$f'(x)$  — вполне реальная, но весьма дорогостоящая операция. В этих случаях приходится модифицировать метод, избегая непосредственного вычисления производной. Некоторые из таких модификаций приведены в § 4.7.

Более существенно то, что метод Ньютона обладает, вообще говоря, только *локальной сходимостью*. Это означает, что областью его сходимости является некоторая малая  $\sigma$ -окрестность корня  $\bar{x}$  и для гарантии сходимости необходимо выбирать хорошее начальное приближение, попадающее в эту  $\sigma$ -окрестность. Неудачный выбор начального приближения может дать расходящуюся последовательность (рис. 4.10) и даже привести к аварийному останову (если на очередной итерации  $f'(x^{(n)}) \approx 0$ ). Для преодоления этой трудности часто используют метод Ньютона в сочетании с каким-либо медленно, но гарантированно сходящимся методом типа бисекции. Такие гибридные алгоритмы находят в последнее время широкое практическое применение.

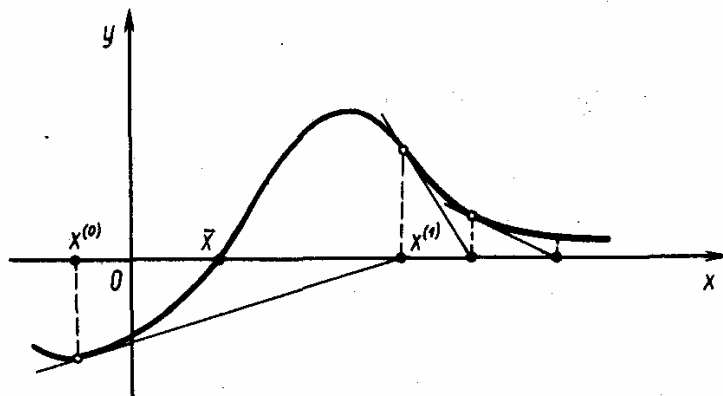


Рис. 4.10

**7. Влияние погрешности вычислений.** Пусть  $\bar{x}$  — простой корень. Если метод Ньютона рассматривать как вариант метода простой итерации, связанный с преобразованием уравнения  $f(x) = 0$  к виду (4.45), то можно воспользоваться результатами § 4.4 и § 4.5.

Поскольку  $\varphi'_N(\bar{x}) = 0$ , справедливо неравенство (4.30) и радиус интервала неопределенности корня  $\bar{x}$  равен примерно  $\bar{\Delta}(\varphi_N^*)$ . В оценках (4.32)—(4.34) можно считать  $\bar{\epsilon}^* \approx \bar{\Delta}(\varphi_N^*)$  и  $C \approx 1$ . Для того чтобы сделать окончательные выводы, остается оценить  $\bar{\Delta}(\varphi_N^*)$ .

Пусть  $f^*$  и  $(f')^*$  — приближенные значения функций  $f$  и  $f'$ , вычисляемые в малой окрестности корня  $\bar{x}$ . Будем считать, что производная  $f'$  вычисляется хотя бы с точностью до 1—2 верных значащих цифр. В противном случае (особенно, если неверно определяется знак  $f'$ ) из геометрического смысла метода легко понять, что его применять не следует. В силу предложения 2.5 в малой окрестности корня имеем

$$\bar{\Delta} \left[ \frac{f^*}{(f')^*} \right] \approx \frac{\bar{\Delta}(f^*)}{|f'|} + \frac{\bar{\Delta}((f')^*)|f|}{|f'|^2} \approx \frac{\bar{\Delta}(f^*)}{|f'(\bar{x})|} = \bar{\varepsilon}.$$

Так как  $\varphi_N^*(x) = x \ominus \frac{f^*(x)}{(f')^*(x)}$ , то, учитывая погрешность  $\approx |\bar{x}|\varepsilon_m$ , вносимую в  $\varphi_N^*$  вследствие выполнения операции вычитания, получим  $\Delta(\varphi_N^*) \approx \bar{\varepsilon} + |\bar{x}|\varepsilon_m$ .

Таким образом, преобразование уравнения  $f(x) = 0$  к виду (4.45) практически не меняет обусловленность и радиус  $\bar{\varepsilon}$  интервала неопределенности корня  $\bar{x}$ . Итерационный процесс Ньютона дает возможность вычислить решение с точностью  $\varepsilon \gtrsim \bar{\varepsilon}$ . Отметим, тем не менее, что эти достоинства метода Ньютона реализуются, вообще говоря, только в малой окрестности корня.

#### § 4.7. Модификации метода Ньютона

В предыдущем параграфе в качестве недостатка метода Ньютона была отмечена необходимость вычисления значения производной  $f'(x)$  на каждой итерации. Рассмотрим некоторые модификации метода Ньютона, свободные от этого недостатка. Заметим, что, по существу, излагаемые в этом разделе итерационные методы решения нелинейного уравнения на каждой итерации используют некоторую процедуру его линеаризации, т. е. исходное нелинейное уравнение заменяется приближенно более простым линейным уравнением.

**1. Упрощенный метод Ньютона.** Если производная  $f'(x)$  непрерывна, то ее значение вблизи простого корня  $\bar{x}$  почти постоянно. Поэтому можно попытаться вычислить  $f'$  лишь однажды в точке  $x^{(0)}$ , а затем заменить в формуле (4.37) значение  $f'(x^{(n)})$  постоянной  $f'(x^{(0)})$ . В результате получим расчетную формулу *упрощенного метода Ньютона*:

$$x^{(n+1)} = x^{(n)} - \frac{f(x^{(n)})}{f'(x^{(0)})}, \quad n \geq 0. \quad (4.46)$$

Геометрическая иллюстрация метода приведена на рис. 4.11. В точке  $(x^{(0)}, f(x^{(0)}))$  к графику функции  $y = f(x)$  проводится касательная  $l_0$  и за приближение  $x^{(1)}$  принимается абсцисса точки пересечения этой касательной с осью  $Ox$  (как в методе Ньютона). Каждое следующее приближение  $x^{(n+1)}$  получается здесь как абсцисса точки пересечения с осью  $Ox$  прямой, проходящей через точку  $M^{(n)}$  с координатами  $(x^{(n)}, f(x^{(n)}))$  и параллельной касательной  $l_0$ .

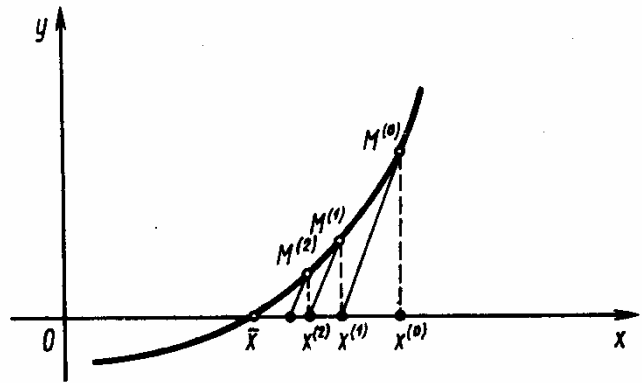


Рис. 4.11

Упрощение вычислений по сравнению с методом Ньютона достигается здесь ценой резкого падения скорости сходимости. Сходимость этого метода является уже не квадратичной, а линейной.

Метод (4.46) можно рассматривать как метод простой итерации с итерационной функцией  $\varphi(x) = x - \frac{f(x)}{f'(x^{(0)})}$ . Так как  $\varphi'(x) = 1 - \frac{f'(x)}{f'(x^{(0)})}$ , то для знаменателя  $q$  соответствующей геометрической

прогрессии имеем  $q \approx \left| 1 - \frac{f'(\bar{x})}{f'(x^{(0)})} \right|$ . Следовательно, скорость сходимости тем выше, чем ближе начальное приближение  $x^{(0)}$  к решению  $\bar{x}$ .

**2. Метод ложного положения.** В основе этой и следующих двух модификаций метода Ньютона лежит приближенное равенство

$$f'(x^{(n)}) \approx \frac{f(z^{(n)}) - f(x^{(n)})}{z^{(n)} - x^{(n)}}. \quad (4.47)$$

Оно верно при условии  $z^{(n)} \approx x^{(n)}$  и следует из определения производной:  $f'(x) = \lim_{z \rightarrow x} \frac{f(z) - f(x)}{z - x}$ .

Пусть  $c$  — фиксированная точка, расположенная в окрестности простого корня  $\bar{x}$ . Заменим в расчетной формуле метода Ньютона (4.37) производную  $f'(x^{(n)})$  правой частью приближенного равенства (4.47), полагая  $z^{(n)} = c$ . В результате придем к расчетной формуле метода ложного положения:

$$x^{(n+1)} = x^{(n)} - \frac{c - x^{(n)}}{f(c) - f(x^{(n)})} f(x^{(n)}), \quad n \geq 0. \quad (4.48)$$

Геометрическая иллюстрация метода приведена на рис. 4.12. Очередное приближение  $x^{(n+1)}$  получается здесь как абсцисса точки пересечения с осью  $Ox$  прямой, проведенной через расположенные на графике функции  $y = f(x)$  точки  $M$  и  $M^{(n)}$  с координатами  $(c, f(c))$  и  $(x^{(n)}, f(x^{(n)}))$ .

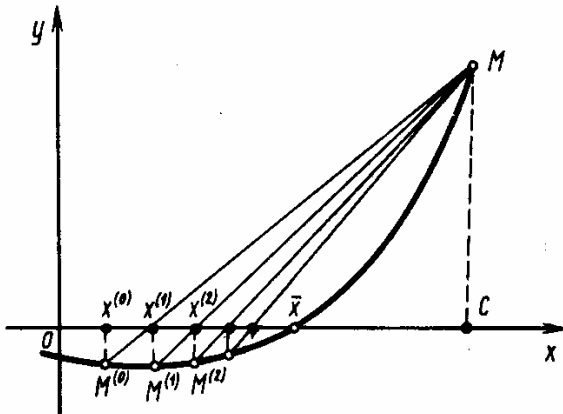


Рис. 4.12

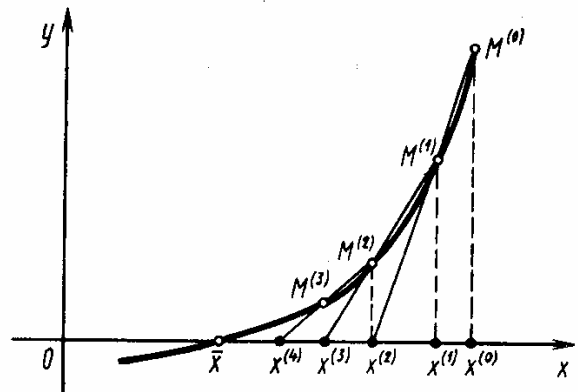


Рис. 4.13

Метод (4.48) обладает только линейной сходимостью. Его можно рассматривать как метод простой итерации с итерационной функцией  $\varphi(x) = x - \frac{c - x}{f(c) - f(x)} f(x)$ . Так как скорость сходимости определяется

вблизи корня величиной  $q \approx |\varphi'(\bar{x})| = \left| 1 - \frac{(c - x) f'(\bar{x})}{f(c) - f(\bar{x})} \right|$ , то она

тем выше, чем ближе окажется выбранная точка  $c$  к  $\bar{x}$ .

**3. Метод секущих.** Замена в формуле метода Ньютона производной  $f'(x^{(n)})$  приближением  $\frac{f(x^{(n-1)}) - f(x^{(n)})}{x^{(n-1)} - x^{(n)}}$  приводит к расчетной формуле *метода секущих*:

$$x^{(n+1)} = x^{(n)} - \frac{x^{(n-1)} - x^{(n)}}{f(x^{(n-1)}) - f(x^{(n)})} f(x^{(n)}), \quad n \geq 1. \quad (4.49)$$

Заметим, что этот метод двухшаговый, так как для нахождения очередного приближения  $x^{(n+1)}$  требуется знание двух предыдущих приближений  $x^{(n)}$  и  $x^{(n-1)}$ . В частности, для того чтобы начать вычисления, необходимо задать два начальных приближения  $x^{(0)}$  и  $x^{(1)}$ . Все рассмотренные ранее методы требовали для вычисления  $x^{(n+1)}$  только знание  $x^{(n)}$ , т. е. были одношаговыми.

На рис. 4.13 приведена геометрическая иллюстрация метода. Очередное приближение  $x^{(n+1)}$  получается здесь как абсцисса точек пересечения с осью  $Ox$  секущей, соединяющей точки  $M^{(n-1)}$  и  $M^{(n)}$  графика функции  $f(x)$  с координатами  $(x^{(n-1)}, f(x^{(n-1)}))$  и  $(x^{(n)}, f(x^{(n)}))$ .

Примечательно то, что эта модификация метода Ньютона сохраняет свойство сверхлинейной сходимости, если вычисляется простой корень  $\bar{x}$ . Точнее, верно следующее утверждение.

**Теорема 4.9.** Пусть  $\bar{x}$  — простой корень уравнения  $f(x) = 0$ , в некоторой окрестности которого функция  $f$  дважды непрерывно дифференцируема, причем  $f'(\bar{x}) \neq 0$ . Тогда существует  $\sigma$ -окрестность корня  $\bar{x}$  такая, что при произвольном выборе приближений  $x^{(0)}$  и  $x^{(1)}$  из этой  $\sigma$ -окрестности метод секущих сходится с порядком  $p = \frac{\sqrt{5} + 1}{2} \approx 1.618$ , т. е. для  $n \geq 1$  справедлива оценка

$$|x^{(n+1)} - \bar{x}| \leq c |x^{(n)} - \bar{x}|^p, \quad p = \frac{\sqrt{5} + 1}{2}.$$

Так как одна итерация метода секущих требует только одного нового вычисления значения функции  $f$ , а метод Ньютона — двух вычислений значений функций ( $f$  и  $f'$ ), то трудоемкость двух итераций метода секущих приблизительно эквивалентна трудоемкости одной итерации по Ньютону. Две итерации метода секущих дают порядок  $p^2 \approx 2.618 > 2$ , поэтому его можно расценивать как более быстрый по сравнению с методом Ньютона.

К сожалению, метод обладает, вообще говоря, только локальной сходимостью. Он требует выбора двух близких к  $\bar{x}$  (в общем случае — очень близких) начальных приближений  $x^{(0)}$  и  $x^{(1)}$ . Если эти приближения выбраны неудачно, то метод расходится (рис. 4.14).

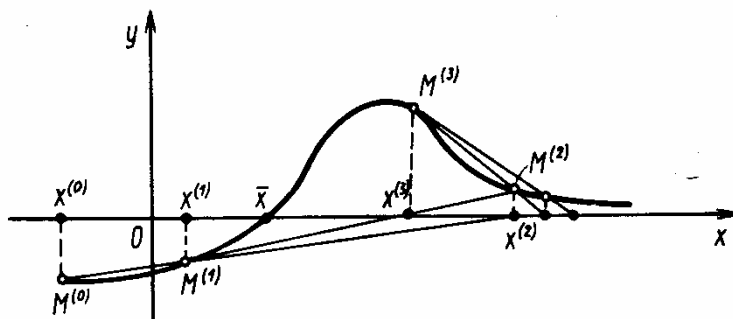


Рис. 4.14



**4. Метод Стеффенсена.** Итерационная формула метода Стеффенсена имеет вид

$$x^{(n+1)} = x^{(n)} - \frac{f(x^{(n)})}{f(x^{(n)} + f(x^{(n)})) - f(x^{(n)})} f(x^{(n)}), \quad n \geq 0. \quad (4.50)$$

Можно считать, что она получена в результате замены производной  $f'(x^{(n)})$ , входящей в расчетную формулу метода Ньютона, приближением (4.47), где  $z^{(n)} = x^{(n)} + f(x^{(n)})$ .

Метод Стеффенсена интересен тем, что он является одношаговым, не требует вычисления производной  $f'$  и в то же время, как и метод Ньютона, сходится квадратично, если корень  $\bar{x}$  — простой, функция  $f$  дважды непрерывно дифференцируема в окрестности корня, а начальное приближение  $x^{(0)}$  выбрано близко к  $\bar{x}$ .

Геометрическая иллюстрация метода Стеффенсена приведена на рис. 4.15. Приближение  $x^{(n+1)}$  получается как абсцисса точки пересечения с осью  $Ox$  секущей,

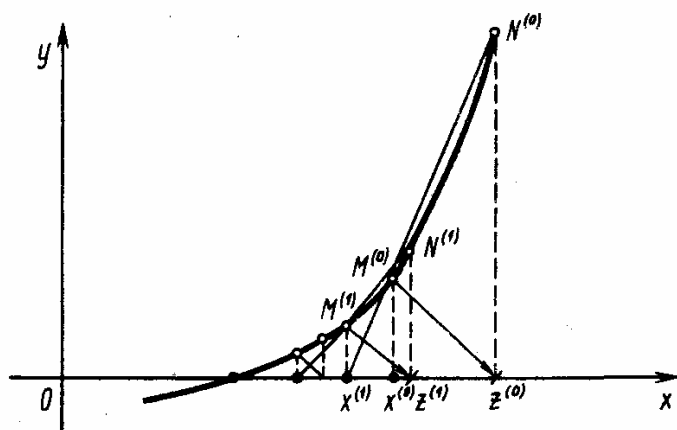


Рис. 4.15

проходящей через точки  $M^{(n)}$  и  $N^{(n)}$  с координатами  $(x^{(n)}, f(x^{(n)}))$  и  $(z^{(n)}, f(z^{(n)}))$ . Значение  $z^{(n)}$  отвечает абсциссе точки пересечения с осью  $Ox$  прямой  $y = f(x^{(n)}) - (x - x^{(n)})$ , проходящей через точку  $M^{(n)}$  и параллельной прямой  $y = -x$ .

Несмотря на свойство квадратичной сходимости, метод Стеффенсена уступает методу

секущих, поскольку требует большей вычислительной работы для достижения той же точности  $\varepsilon$ . Это связано с тем, что на каждой итерации рассматриваемого метода вычисление функции производится дважды, а в методе секущих лишь один раз.

**5. Уточнение метода Ньютона для случая кратного корня.** В принципе для вычисления корня уравнения  $f(x) = 0$  кратности  $m > 1$  можно использовать и стандартный метод Ньютона. Однако в этом случае скорость его сходимости является только линейной. Можно показать, что знаменатель  $q$  соответствующей геометрической прогрессии приближенно равен  $1 - \frac{1}{m}$ .

Для того чтобы сохранить квадратичную скорость сходимости, метод Ньютона нужно модифицировать следующим образом:

$$x^{(n+1)} = x^{(n)} - m \frac{f(x^{(n)})}{f'(x^{(n)})}, \quad n \geq 0. \quad (4.51)$$

Можно показать (это достигается раскрытием неопределенностей с помощью формулы Тейлора), что при таком выборе итерационной функции  $\varphi(x) = x - m \frac{f(x)}{f'(x)}$  получим  $\varphi'(\bar{x}) = 0$ , и сходимость снова окажется квадратичной.

На рис. 4.16, а, б проиллюстрировано поведение последовательных приближений стандартного метода Ньютона и его модификации (4.51) для случая отыскания корня кратности  $m = 2$ .

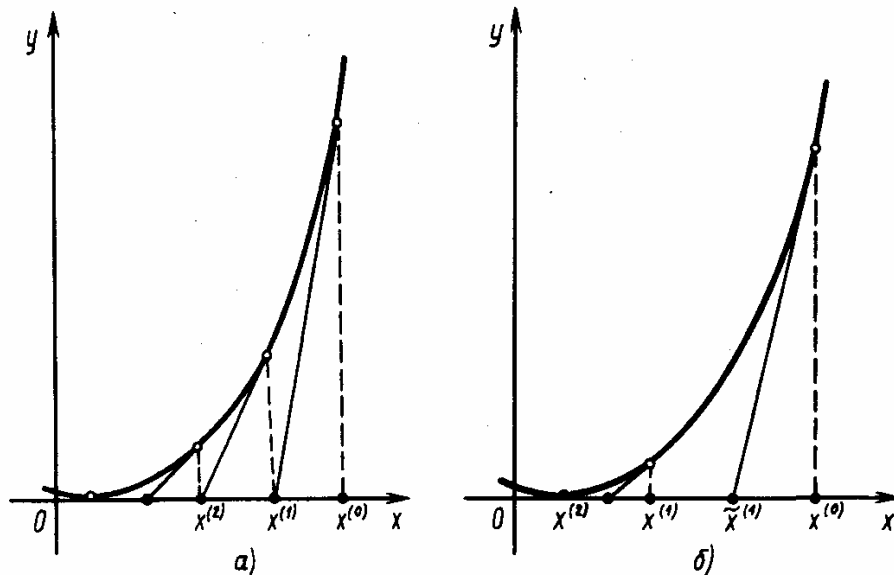


Рис. 4.16

Для метода (4.51) значение  $x^{(n+1)}$  получается следующим образом. В точке  $M^{(n)}$  с координатами  $(x^{(n)}, f(x^{(n)}))$  к графику функции проводится касательная. Пересечение ее с осью  $Ox$  дает вспомогательную точку  $\tilde{x}^{(n+1)}$ . Для получения точки  $x^{(n+1)}$  нужно воспользоваться равенством  $x^{(n+1)} - x^{(n)} = m (\tilde{x}^{(n+1)} - x^{(n)})$ .

**Пример 4.10.** Применим методы, рассмотренные в данной главе, для вычисления положительного корня уравнения  $4(1 - x^2) - e^x = 0$ , считая известным, что  $\bar{x} \in [0, 1]$  (см. пример 4.2).

Результаты вычислений приведены в табл. 4.5—4.8. В них для каждого приближения дается число верных знаков и требуемое число вычислений

значений функции  $f(x) = 4(1 - x^2) - e^x$  (для упрощенного метода Ньютона учтено вычисление  $f'(x^{(0)})$ ). Вычисления выполнены с 10 знаками мантиссы.

Отметим, что выбор начальных приближений был довольно случайным (хотя и разумным). Тем не менее лучший результат показал метод секущих. Решение с 10 верными знаками мантиссы было получено после 5 итераций и для этого потребовалось лишь 6 вычислений функции. Хотя метод Ньютона (см. пример 4.8) при том же начальном приближении  $x^{(0)}$  дает такое же значение  $\bar{x}$  всего после 4 итераций, для этого требуется 8 вычислений функции (4 вычисления  $f$  и 4 вычисления  $f'$ ).

**Пример 4.11.** Применим метод Ньютона и его модификацию (4.51) для вычисления корня  $\bar{x} = 0$  кратности  $m = 2$  для уравнения  $x^2 e^x = 0$ . Возьмем  $x^{(0)} = 1$ . Результаты вычислений даны в табл. 4.9 и 4.10.

Как видно из табл. 4.9, погрешность метода Ньютона убывает довольно медленно и соответствует примерно геометрической прогрессии со знаменателем  $q = 1/2$ . В то же время 5 итераций по формуле (4.51) при  $m = 2$  дают значение решения с погрешностью, меньшей  $\varepsilon = 10^{-10}$ .

Т а б л и ц а 4.5

Упрощенный метод Ньютона;  
 $x^{(0)} = 0.5$

$n$	$x^{(n)}$	Число верных знаков	Число вычис- лений функций
0	0.5000000000	0	0
1	0.7392185177	1	2
2	0.6896366262	1	3
3	0.7081565866	2	4
4	0.7017501401	2	5
5	0.7040350503	3	6
6	0.7032284740	3	7
7	0.7035142540	4	8
8	0.7034131306	4	9
9	0.7034489297	4	10
10	0.7034362584	5	11

Т а б л и ц а 4.6

Метод ложного положения;  
 $c = 1, x^{(0)} = 0.5$

$n$	$x^{(n)}$	Число верных знаков	Число вычис- лений функций
0	0.5000000000	0	0
1	0.6660226835	1	2
2	0.6971284254	2	3
3	0.7023912700	2	4
4	0.7032658920	3	5
5	0.7034108088	4	6
6	0.7034348083	5	7
7	0.7034387825	6	8
8	0.7034394406	6	9
9	0.7034395495	7	10
10	0.7034395676	8	11

Т а б л и ц а 4.7

Метод секущих;  
 $x^{(0)} = 1, x^{(1)} = 0.5$

$n$	$x^{(n)}$	Число верных знаков	Число вычис- лений функций
0	1.0000000000	0	0
1	0.5000000000	0	0
2	0.6660226835	1	2
3	0.7092548653	2	3
4	0.7032943284	3	4
5	0.7034390197	6	5
6	0.7034395712	10	6

Т а б л и ц а 4.8

Метод Стеффенсена;  
 $x^{(0)} = 0.5$

$n$	$x^{(n)}$	Число верных знаков	Число вычис- лений функций
0	0.5000000000	0	0
1	0.6047702913	0	2
2	0.6731754719	1	4
3	0.6998880287	2	6
4	0.7033854199	3	8
5	0.7034395584	7	10
6	0.7034395712	10	12

Т а б л и ц а 4.9

Метод Ньютона

$n$	$x^{(n)}$
0	1.0000000000
1	0.6666666667
2	0.4166666667
3	0.2442528736
4	0.1354180464
5	0.0720028071
6	0.0372524647
7	0.0189668249
8	0.0095725027

Т а б л и ц а 4.10

Уточнение метода Ньютона для  
 случая  $m = 2$

$n$	$x^{(n)}$
0	1.0000000000
1	0.3333333333
2	0.0476190476
3	0.0011074197
4	0.0000006128
5	0.0000000000

**6. Чувствительность к погрешностям.** Рассмотренные в этом параграфе одношаговые методы можно интерпретировать как различные варианты метода простой итерации. Поэтому исследование их чувствительности к погрешностям сводится (аналогично тому, как это было сделано в предыдущем параграфе для метода Ньютона) к использованию соответствующих результатов § 4.5. Так, например, можно убе-

даться в хорошей обусловленности модифицированного метода Ньютона и метода ложного положения.

Высокая скорость сходимости метода секущих делает его привлекательным для применения. Однако вызывает беспокойство тот факт, что в формулу (4.49) входит величина  $\frac{f(x^{(n-1)}) - f(x^{(n)})}{x^{(n-1)} - x^{(n)}}$ , аппроксимирующая производную. Вблизи корня, когда  $x^{(n)} \approx x^{(n-1)}$  и  $f(x^{(n)}) \approx f(x^{(n-1)}) \approx 0$ , погрешность вычисления функции начинает существенно сказываться на точности этой величины, и метод секущих теряет устойчивость. Этим он существенно отличается от методов простой итерации и Ньютона, для которых приближения  $x^{(n)}$  равномерно устойчивы к погрешности независимо от числа итераций  $n$ .

Тем не менее при грамотном использовании метод секущих дает возможность получить почти столько же верных значащих цифр корня  $\bar{x}$ , сколько вообще позволяет обусловленность задачи (см. § 4.2). Возможная (но не обязательная) потеря точности составляет 1—2 верные цифры. Необходимо лишь прервать итерационный процесс в тот момент, когда приближения окажутся в опасной близости к интервалу неопределенности. Один из способов заметить этот момент состоит в использовании правила Гарвика (см. § 4.2).

Отметим, что при попадании очередного приближения в малую окрестность решения теряет устойчивость и метод Стеффенсена.

#### § 4.8. Дополнительные замечания

**1. Метод обратной квадратичной интерполяции.** Пусть приближения  $x^{(n-2)}$ ,  $x^{(n-1)}$ ,  $x^{(n)}$  уже найдены, а соответствующие значения функции  $f$  различны (последнее предположение заведомо будет выполнено, если функция  $f$  строго монотонна). Тогда строят такой квадратичный многочлен  $P_2(y)$  от переменной  $y$ , что  $x^{(i)} = P_2(f(x^{(i)}))$  для  $i = n-2, n-1, n$ . За очередное приближение к решению принимается  $x^{(n+1)} = P_2(0)$ .

Этот трехшаговый метод обладает локальной сходимостью с порядком  $p \approx 1.839$ ; для начала его работы требуется задание трех хороших начальных приближений.

**2. Методы с порядком сходимости выше второго.** Приведем пример одношагового метода, обладающего кубической сходимостью:

$$x^{(n+1)} = x^{(n)} - \frac{f(x^{(n)})}{f'(x^{(n)})} - \frac{f''(x^{(n)})}{2(f'(x^{(n)}))^2} \frac{f(x^{(n)})^2}{f'(x^{(n)})}.$$

Существуют и другие методы с порядком сходимости выше второго, теоретически очень быстро сходящиеся вблизи корня. Однако они редко используют-

ся на практике, так как их преимущество в скорости сходимости начинает проявляться лишь тогда, когда итерации уже почти сошлись и в действительности осталось сделать 1—2 итерации либо вообще пора прекратить вычисления. Чтобы ощутить преимущество таких методов над методами Ньютона и секущих, нужна ЭВМ с очень высокой разрядностью и желание получить решение с чрезвычайно высокой точностью.

**3. Вычисление корней многочленов.** Вычисление корней многочленов  $P_n(x)$  степени  $n$  — специальная задача, для решения которой разработано большое число эффективных алгоритмов. Укажем на один из них — *метод Мюллера*. В нем по трем ранее найденным приближениям  $x^{(n-2)}$ ,  $x^{(n-1)}$ ,  $x^{(n)}$  строят интерполяционный многочлен второй степени  $Q_2(x)$ , т. е. такой многочлен для которого  $Q_2(x^{(i)}) = f(x^{(i)})$  при  $i = n-2, n-1, n$ . За очередное приближение  $x^{(n+1)}$  принимают тот из двух корней многочлена  $Q_2(x)$  (в общем случае являющихся комплексными), который расположен ближе к  $x^{(n)}$ .

Вплоть до начала 60-х годов задача вычисления корней многочленов была весьма распространенной. Одна из основных причин состояла в том, что к отысканию корней характеристического многочлена сводилась одна из важнейших задач алгебры — задача вычисления собственных чисел матриц. В настоящее время существуют другие, гораздо более эффективные численные методы вычисления собственных значений (см. гл. 8), и, по-видимому, задача вычисления корней многочлена во многом потеряла свою актуальность.

Как было отмечено ранее, к задаче отыскания корней многочлена высокой степени с приближенно заданными коэффициентами следует относиться очень внимательно: она может оказаться плохо обусловленной (см. в гл. 3 пример Уилкинсона). Вообще, можно посоветовать избегать применения методов решения вычислительных задач, в которых используются многочлены высокой степени.

**4. Гибридные алгоритмы.** В последние годы получили признание алгоритмы, которые называют *гибридными* (или *регуляризованными*). Они представляют собой комбинации надежных, но медленно сходящихся методов типа бисекции с недостаточно надежными, но быстро сходящимися методами типа секущих и Ньютона. Результирующие алгоритмы обладают высокой надежностью и гарантированной сходимостью. В тех же случаях, когда в окрестности простого корня функции  $f$  — гладкая, сходимость становится сверхлинейной.

Алгоритм ZEROIN, изложенный в [86], является примером эффективного гибридного алгоритма, на каждом шаге которого принимается решение о том, какой из трех методов: бисекции, секущих или обратной квадратичной интерполяции — следует использовать для вычисления очередного приближения.

**5. Критерии окончания.** Проблема выбора правильного критерия окончания итерационного процесса часто оказывается достаточно сложной. Следует иметь в виду, что наряду с обсуждавшимся в предыдущих параграфах условием  $|x^{(n)} - x^{(n-1)}| < \epsilon_1$  нередко используется следующее условие:  $|f(x^{(n)})| < \epsilon_2$ .

## Глава 5

# ПРЯМЫЕ МЕТОДЫ РЕШЕНИЯ СИСТЕМ ЛИНЕЙНЫХ АЛГЕБРАИЧЕСКИХ УРАВНЕНИЙ

### § 5.1. Постановка задачи

В вычислительной линейной алгебре выделяют четыре основные задачи: 1) решение систем линейных алгебраических уравнений; 2) вычисление определителей; 3) нахождение обратных матриц; 4) определение собственных значений и собственных векторов. Задачи 2 и 3 обсуждаются в § 5.6, последней по порядку (но не по значению) задаче 4 посвящена гл. 8.

В основном же данная глава посвящена задаче 1, а более точно — прямым методам решения систем линейных алгебраических уравнений с вещественными коэффициентами:

[illegible]

В матричной форме записи эта система принимает вид

$$Ax = b, \quad (5.2)$$

где

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1m} \\ a_{21} & a_{22} & a_{23} & \dots & a_{2m} \\ a_{31} & a_{32} & a_{33} & \dots & a_{3m} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & a_{m3} & \dots & a_{mm} \end{bmatrix}, \quad x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_m \end{bmatrix}, \quad b = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \\ \vdots \\ b_m \end{bmatrix}.$$

Итерационные методы решения системы (5.1) будут рассмотрены в гл. 6.

Уделим основное внимание задаче вычисления вектора  $\mathbf{x}$ , являющегося решением системы (5.2), по входному данному — вектору  $\mathbf{b}$ . Будем предполагать, что матрица  $\mathbf{A}$  задана и является невырожденной. Известно, что в этом случае решение системы существует, единственно и устойчиво по входным данным. Это означает, что рассматриваемая задача корректна.

Хотя задача решения системы (5.1) сравнительно редко представляет самостоятельный интерес для приложений, от умения эффективно решать такие системы часто зависит сама возможность математического моделирования самых разнообразных процессов с применением ЭВМ. Как будет видно из дальнейшего изложения, значительная часть численных методов решения различных (в особенности — нелинейных) задач включает в себя решение систем (5.1) как элементарный шаг соответствующего алгоритма.

Пусть  $\mathbf{x}^* = (x_1^*, x_2^*, \dots, x_m^*)^T$  — приближенное решение системы (5.1).

В этой и следующих главах мы будем стремиться к получению решения, для которого погрешность  $\mathbf{e} = \mathbf{x} - \mathbf{x}^*$  мала (количественные характеристики "величины" погрешности будут введены в следующем параграфе). Тем не менее заметим, что качество полученного решения далеко не всегда характеризуется тем, насколько мала погрешность  $\mathbf{x} - \mathbf{x}^*$ . Иногда вполне удовлетворительным является критерий малости невязки  $\mathbf{r} = \mathbf{b} - \mathbf{A}\mathbf{x}^*$ . Вектор  $\mathbf{r}$  показывает, насколько отличается правая часть системы от левой, если подставить в нее приближенное решение. Заметим, что  $\mathbf{r} = \mathbf{A}\mathbf{x} - \mathbf{A}\mathbf{x}^* = \mathbf{A}(\mathbf{x} - \mathbf{x}^*)$  и поэтому погрешность и невязка связаны равенством

$$\mathbf{e} = \mathbf{x} - \mathbf{x}^* = \mathbf{A}^{-1}\mathbf{r}. \quad (5.3)$$

## § 5.2. Нормы вектора и матрицы

**1. Норма вектора.** Решением системы линейных алгебраических уравнений является вектор  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$ , который будем рассматривать как элемент векторного пространства  $R^m$ . Приближенное решение  $\mathbf{x}^* = (x_1^*, x_2^*, \dots, x_m^*)^T$  и погрешность  $\mathbf{e} = \mathbf{x} - \mathbf{x}^* = (x_1 - x_1^*, \dots, x_m - x_m^*)^T$  также являются элементами пространства  $R^m$ . Для того чтобы анализировать методы решения систем, необходимо уметь количественно оценивать "величины" векторов  $\mathbf{x}^*$  и  $\mathbf{x} - \mathbf{x}^*$ , а также векторов  $\mathbf{b}$  и



$b - b^*$ , где  $b^* = (b_1^*, b_2^*, \dots, b_m^*)^T$  — вектор приближенно заданных правых частей. Удобной для этой цели количественной характеристикой является широко используемое понятие нормы вектора.

Говорят, что в  $R^m$  задана норма, если каждому вектору  $x$  из  $R^m$  сопоставлено вещественное число  $\|x\|$ , называемое *нормой вектора  $x$*  и обладающее следующими свойствами:

1<sup>0</sup>)  $\|x\| \geq 0$ , причем  $\|x\| = 0$  тогда и только тогда, когда  $x = 0$ ;

2<sup>0</sup>)  $\|\alpha x\| = |\alpha| \|x\|$  для любого вектора  $x$  и любого числа  $\alpha$ ;

3<sup>0</sup>)  $\|x + y\| \leq \|x\| + \|y\|$  для любых векторов  $x$  и  $y$ ;

последнее неравенство принято называть *неравенством треугольника*.

Заметим, что такими же свойствами обладает обычная геометрическая длина вектора в трехмерном пространстве. Свойство 3<sup>0</sup> в этом случае следует из правила сложения векторов и из того известного факта, что сумма длин двух сторон треугольника всегда больше длины третьей стороны.

Существует множество различных способов введения норм. В вычислительных методах наиболее употребительными являются следующие три нормы:

$$\|x\|_1 = \sum_{i=1}^m |x_i|, \quad \|x\|_2 = \left( \sum_{i=1}^m |x_i|^2 \right)^{1/2}, \quad \|x\|_\infty = \max_{1 \leq i \leq m} |x_i|. \quad (5.4)$$

Первые две из них являются частными случаями более общей нормы:

$$\|x\|_p = \left( \sum_{i=1}^m |x_i|^p \right)^{1/p}, \quad p \geq 1 \quad (5.5)$$

(при  $p = 1$  и  $p = 2$ ), а последняя, как можно показать, получается из нормы (5.5) предельным переходом при  $p \rightarrow \infty$ .

**З а м е ч а н и е 1.** Норма  $\|x\|_2$  является естественным обобщением на случай  $m$ -мерного пространства понятия длины вектора в двух- и трехмерных геометрических пространствах. Поэтому ее называют *евклидовой нормой*.

**З а м е ч а н и е 2.** Справедливы неравенства

$$\|x\|_\infty \leq \|x\|_2 \leq \|x\|_1 \leq m \|x\|_\infty, \quad (5.6)$$

указывающие на то, что в определенном смысле все три введенные нормы эквивалентны: каждая из них оценивается любой из двух других норм с точностью до множителя, зависящего от  $m$ .

**Пример 5.1.** Найдем  $\|x\|_1$ ,  $\|x\|_2$ ,  $\|x\|_\infty$  для вектора  $x = (0.12, -0.15, 0.16)^T$ .

По формулам (5.4) определяем  $\|\mathbf{x}\|_1 = 0.12 + 0.15 + 0.16 = 0.43$ ,  $\|\mathbf{x}\|_2 = (0.12^2 + 0.15^2 + 0.16^2)^{1/2} = 0.25$ ,  $\|\mathbf{x}\|_\infty = \max \{0.12, 0.15, 0.16\} = 0.16$ .

**2. Скалярное произведение.** Напомним, что скалярным произведением векторов  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$  и  $\mathbf{y} = (y_1, y_2, \dots, y_m)^T$  называется величина

$$(\mathbf{x}, \mathbf{y}) = x_1 y_1 + x_2 y_2 + \dots + x_m y_m = \sum_{i=1}^m x_i y_i. \quad (5.7)$$

Нетрудно установить, что  $\|\mathbf{x}\|_2 = (\mathbf{x}, \mathbf{x})^{1/2}$ .

В случае, когда векторы  $\mathbf{x}$ ,  $\mathbf{y}$  имеют комплексные компоненты, скалярное произведение понимают так:

$$(\mathbf{x}, \mathbf{y}) = x_1 \bar{y}_1 + x_2 \bar{y}_2 + \dots + x_m \bar{y}_m.$$

**3. Абсолютная и относительная погрешности вектора.** Далее будем всюду считать, что в пространстве  $m$ -мерных векторов  $R^m$  введена и фиксирована некоторая норма  $\|\mathbf{x}\|$  (например, одна из норм  $\|\mathbf{x}\|_p$ ,  $1 \leq p \leq \infty$ ). В этом случае в качестве меры степени близости векторов  $\mathbf{x}$  и  $\mathbf{x}^*$  естественно использовать величину  $\|\mathbf{x} - \mathbf{x}^*\|$ , являющуюся аналогом расстояния между точками  $\mathbf{x}$  и  $\mathbf{x}^*$ . Введем абсолютную и относительную погрешности вектора  $\mathbf{x}^*$  с помощью формул

$$\Delta(\mathbf{x}^*) = \|\mathbf{x} - \mathbf{x}^*\|, \quad \delta(\mathbf{x}^*) = \frac{\|\mathbf{x} - \mathbf{x}^*\|}{\|\mathbf{x}\|}. \quad (5.8)$$

Выбор той или иной конкретной нормы в практических задачах диктуется тем, какие требования предъявляются к точности решения. Выбор нормы  $\|\mathbf{x}\|_1$  фактически отвечает случаю, когда малой должна быть суммарная абсолютная ошибка в компонентах решения; выбор  $\|\mathbf{x}\|_2$  соответствует критерию малости среднеквадратичной ошибки, а принятие в качестве нормы  $\|\mathbf{x}\|_\infty$  означает, что малой должна быть максимальная из абсолютных ошибок в компонентах решения.

**4. Сходимость по норме.** Пусть  $\{\mathbf{x}^{(n)}\}_{n=1}^\infty$  — последовательность векторов  $\mathbf{x}^{(n)} = (x_1^{(n)}, x_2^{(n)}, \dots, x_m^{(n)})^T$ . Говорят, что последовательность векторов  $\mathbf{x}^{(n)}$  сходится к вектору  $\mathbf{x}$  при  $n \rightarrow \infty$  ( $\mathbf{x}^{(n)} \rightarrow \mathbf{x}$  при  $n \rightarrow \infty$ ), если  $\Delta(\mathbf{x}^{(n)}) = \|\mathbf{x}^{(n)} - \mathbf{x}\| \rightarrow 0$  при  $n \rightarrow \infty$ .

**З а м е ч а н и е.** Сам факт наличия или отсутствия сходимости  $\mathbf{x}^{(n)}$  к  $\mathbf{x}$  при  $n \rightarrow \infty$  в конечномерных пространствах не зависит от выбора нормы. Известно, что из сходимости последовательности по

одной из норм следует сходимость этой последовательности в  $R^m$  по любой другой норме. Например, для норм  $\|x\|_1$ ,  $\|x\|_2$ ,  $\|x\|_\infty$  это вытекает из неравенств (5.6). Более того,  $x^{(n)} \rightarrow x$  при  $n \rightarrow \infty$  тогда и только тогда, когда для всех  $i = 1, 2, \dots, m$  имеем  $x_i^{(n)} \rightarrow x_i$  при  $n \rightarrow \infty$ , т. е. сходимость по норме в  $R^m$  эквивалентна покомпонентной (покоординатной) сходимости.

## 5. Норма матрицы. Величина

$$\|A\| = \max_{x \neq 0} \frac{\|Ax\|}{\|x\|} \quad (5.9)$$

называется *нормой матрицы*  $A$ , подчиненной норме векторов, введенной в  $R^m$ .

Заметим, что множество всех квадратных матриц размера  $m \times m$  является векторным пространством. Можно показать, что введенная в этом пространстве формулой (5.9) норма обладает следующими свойствами, аналогичными свойствам нормы вектора:

1<sup>0</sup>)  $\|A\| \geq 0$ , причем  $\|A\| = 0$  тогда и только тогда, когда  $A = 0$ .

2<sup>0</sup>)  $\|\alpha A\| = |\alpha| \cdot \|A\|$  для любой матрицы  $A$  и любого числа  $\alpha$ .

3<sup>0</sup>)  $\|A + B\| \leq \|A\| + \|B\|$  для любых матриц  $A$  и  $B$ .

Дополнительно к этому верны следующие свойства:

4<sup>0</sup>)  $\|A \cdot B\| \leq \|A\| \cdot \|B\|$  для любых матриц  $A$  и  $B$ ;

5<sup>0</sup>) для любой матрицы  $A$  и любого вектора  $x$  справедливо неравенство

$$\|Ax\| \leq \|A\| \cdot \|x\|. \quad (5.10)$$

Докажем, например, свойство 5<sup>0</sup>. Если  $\|x\| \neq 0$ , то неравенство (5.10) эквивалентно неравенству  $\|Ax\|/\|x\| \leq \|A\|$ , справедливость которого следует из определения (5.9). Если же  $\|x\| = 0$ , то неравенство (5.10) превращается в верное числовое неравенство  $0 \leq 0$ .

Как следует из определения (5.9), каждой из векторных норм  $\|x\|$  соответствует своя подчиненная норма матрицы  $A$ . Известно, в частности, что нормам  $\|x\|_1$ ,  $\|x\|_2$  и  $\|x\|_\infty$  подчинены нормы  $\|A\|_1$ ,  $\|A\|_2$  и  $\|A\|_\infty$ , вычисляемые по формулам

$$\|A\|_1 = \max_{1 \leq j \leq m} \sum_{i=1}^m |a_{ij}|, \quad (5.11)$$

$$\|A\|_2 = \max_{1 \leq j \leq m} \sqrt{\lambda_j(A^T A)}, \quad (5.12)$$

где  $\lambda_j(A^T A)$  — собственные числа<sup>1</sup> матрицы  $A^T A$ ;

$$\|A\|_\infty = \max_{1 \leq i \leq m} \sum_{j=1}^m |a_{ij}|. \quad (5.13)$$

Нормы  $\|A\|_1$  и  $\|A\|_\infty$  вычисляются просто (см. ниже пример 5.2).

Для получения значения первой из них нужно найти сумму модулей элементов каждого из столбцов матрицы  $A$ , а затем выбрать максимальную из этих сумм. Для получения значения  $\|A\|_\infty$  нужно аналогичным образом поступить со строками матрицы  $A$ .

Как правило, вычислить значение нормы  $\|A\|_2$  бывает трудно, так как для этого следует искать собственные числа  $\lambda_j$ . Для оценки величины  $\|A\|_2$  можно, например, использовать неравенство

$$\|A\|_2 \leq \|A\|_E. \quad (5.14)$$

Здесь  $\|A\|_E = \sqrt{\sum_{i,j=1}^m |a_{ij}|^2}$  — величина, называемая *евклидовой нормой матрицы  $A$* .

Норма (5.9) имеет простую геометрическую интерпретацию. Для того чтобы ее привести, заметим, что операцию умножения матрицы  $A$  на вектор  $x$  можно рассматривать как преобразование, которое переводит вектор  $x$  в новый вектор  $y = Ax$ . Если значение  $\|x\|$  интерпретируется как длина вектора  $x$ , то величина  $\|Ax\|/\|x\|$  есть коэффициент растяжения вектора  $x$  под действием матрицы  $A$ . Таким образом, величина

$$k_{\max} = \|A\| = \max_{x \neq 0} \frac{\|Ax\|}{\|x\|} \quad (5.15)$$

представляет собой максимальный коэффициент растяжения векторов под действием матрицы  $A$ . Полезно отметить, что для невырожденной матрицы  $A$  минимальный коэффициент растяжения  $k_{\min}$  отвечает норме обратной матрицы и вычисляется по формуле

$$k_{\min} = \|A^{-1}\|^{-1} = \min_{x \neq 0} \frac{\|Ax\|}{\|x\|}. \quad (5.16)$$

---

<sup>1</sup> Напомним, что число  $\lambda$  называется собственным числом матрицы  $A$ , если  $\det(A - \lambda E) = 0$ . Каждая матрица порядка  $m$  имеет ровно  $m$  собственных чисел (вообще говоря, комплексных) с учетом их кратности.

Заметим, что в случае  $\|A\| < 1$  происходит сжатие векторов под действием матрицы  $A$ .

**Пример 5.2.** Для матрицы

$$A = \begin{bmatrix} 0.1 & -0.4 & 0 \\ 0.2 & 0 & -0.3 \\ 0 & 0.1 & 0.3 \end{bmatrix}$$

найдем  $\|A\|_1$ ,  $\|A\|_\infty$  и оценим  $\|A\|_2$ .

В соответствии с формулами (5.11), (5.13) и неравенством (5.14) имеем

$$\|A\|_1 = \max \{0.1 + 0.2 + 0, 0.4 + 0 + 0.1, 0 + 0.3 + 0.3\} = 0.6,$$

$$\|A\|_\infty = \max \{0.1 + 0.4 + 0, 0.2 + 0 + 0.3, 0 + 0.1 + 0.3\} = 0.5,$$

$$\|A\|_2 \leq \|A\|_E = \left[ \sum_{i,j=1}^3 a_{ij}^2 \right]^{1/2} = \sqrt{0.4} \approx 0.63.$$

### § 5.3. Типы используемых матриц

Эффективность вычислений в линейной алгебре существенно зависит от умения использовать специальную структуру и свойства используемых в расчетах матриц. Напомним некоторые важные типы матриц.

Квадратная матрица  $A$  называется *диагональной*, если ее элементы удовлетворяют условию  $a_{ij} = 0$  для  $i \neq j$  (все отличные от нуля элементы расположены на главной диагонали):

$$A = \begin{bmatrix} a_{11} & 0 & 0 & \dots & 0 \\ 0 & a_{22} & 0 & \dots & 0 \\ 0 & 0 & a_{33} & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & a_{nn} \end{bmatrix}.$$

Диагональную матрицу, у которой все элементы  $a_{ii}$  главной диагонали равны единице, называют *единичной* и обозначают буквой  $E$ :

$$E = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix}.$$

**Пример 5.3.** Вычислим норму единичной матрицы  $E$ .

По определению,  $\|E\| = \max_{x \neq 0} \frac{\|Ex\|}{\|x\|} = \max_{x \neq 0} \frac{\|x\|}{\|x\|} = 1$ . Следовательно,  $\|E\| = 1$ .

Важную роль в численном анализе играют *треугольные матрицы*. Квадратная матрица  $A$  называется *нижней треугольной*, если все ее элементы, расположенные выше главной диагонали, равны нулю ( $a_{ij} = 0$  для  $i < j$ ). Если же равны нулю все элементы матрицы, расположенные ниже главной диагонали ( $a_{ij} = 0$  для  $i > j$ ), то она называется *верхней треугольной*.

Нижняя и верхняя треугольная матрицы имеют соответственно следующий вид:

$$\begin{bmatrix} a_{11} & 0 & 0 & \dots & 0 \\ a_{21} & a_{22} & 0 & \dots & 0 \\ a_{31} & a_{32} & a_{33} & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ a_{m1} & a_{m2} & a_{m3} & \dots & a_{mm} \end{bmatrix}, \quad \begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1m} \\ 0 & a_{22} & a_{23} & \dots & a_{2m} \\ 0 & 0 & a_{33} & \dots & a_{3m} \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & a_{mm} \end{bmatrix}.$$

Треугольные матрицы обладают рядом замечательных свойств. Например, для таких матриц определитель легко вычисляется по формуле

$$\det A = a_{11} a_{22} a_{33} \dots a_{mm}. \quad (5.17)$$

Квадратная матрица  $A$  называется *симметричной*, если она совпадает со своей транспонированной матрицей  $A^T$  (или, что то же,  $a_{ij} = a_{ji}$  для всех  $i, j$ ).

Будем называть симметричную матрицу  $A$  *положительно определенной* и писать  $A > 0$ , если для всех векторов  $x \neq 0$  квадратичная форма

$$(Ax, x) = \sum_{i,j=1}^m a_{ij}x_i x_j$$

принимает положительные значения.

Обозначим через  $\lambda_{\min}$  и  $\lambda_{\max}$  минимальное и максимальное собственные значения матрицы  $A$ . Известно, что для симметричной матрицы

$$\lambda_{\min} \|x\|^2 \leq (Ax, x) \leq \lambda_{\max} \|x\|^2$$

и матрица  $A$  положительно определена тогда и только тогда, когда все ее собственные значения положительны.

Одна из трудностей практического решения систем большой размерности связана с ограниченностью оперативной памяти ЭВМ. Хотя объем оперативной памяти вновь создаваемых вычислительных машин растет очень быстро, тем не менее еще быстрее возрастают потребности практики в решении задач все большей размерности (напомним, что

для хранения в оперативной памяти ЭВМ матрицы порядка  $m$  требуется  $m^2$  машинных слов). В значительной степени ограничения на размерность решаемых систем можно снять, если использовать для хранения матрицы внешние запоминающие устройства. Однако в этом случае многократно возрастают как затраты машинного времени, так и сложность соответствующих алгоритмов.

Поэтому при создании вычислительных алгоритмов линейной алгебры большое внимание уделяют способам компактного размещения элементов матриц в памяти ЭВМ. Заметим, что для хранения диагональной матрицы достаточно отвести массив длины  $m$  и расположить в нем элементы  $a_{11}, a_{22}, \dots, a_{mm}$ . Для хранения треугольной матрицы достаточно  $m(m+1)/2$  ячеек памяти, что примерно вдвое меньше места, отводимого для хранения матрицы общего вида. Столько же ячеек используется для хранения симметричной матрицы, поскольку такая матрица полностью определяется, например, заданием своей нижней треугольной части.

К счастью, приложения очень часто приводят к матрицам, в которых число ненулевых элементов много меньше общего числа элементов матрицы. Такие матрицы принято называть *разреженными*. Напротив, матрицы общего вида называют *плотными* (или *заполненными*). Разреженность матрицы является очень ценным свойством, поскольку объем информации, который следует обрабатывать и хранить в памяти ЭВМ, для таких матриц даже очень большого размера может оказаться не слишком большим. Для хранения всех ненулевых элементов и информации об их расположении оказывается достаточным использовать только оперативную память ЭВМ. Иногда элементы матрицы известны либо вычисляются по простым формулам и необходимость в их хранении отпадает.

Одним из основных источников разреженных матриц являются математические модели технических устройств, состоящих из большого числа элементов, связи между которыми локальны. Простейшие примеры таких устройств — сложные строительные конструкции и большие электрические цепи. Другой важный источник разреженности — метод конечных разностей и метод конечных элементов, используемые для решения уравнений математической физики.

Известны примеры решенных в последние годы задач, где число неизвестных достигало сотен тысяч. Естественно, это было бы невозможно, если бы соответствующие матрицы не являлись разреженными (число элементов матрицы при  $m = 10^5$  равно  $m \times m = 10^{10}$ ).

Простой пример разреженной матрицы дает *трехдиагональная матрица*

$$\begin{bmatrix} a_{11} & a_{12} & 0 & 0 & \dots & 0 & 0 & 0 \\ a_{21} & a_{22} & a_{23} & 0 & \dots & 0 & 0 & 0 \\ 0 & a_{32} & a_{33} & a_{34} & \dots & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \dots & a_{m-1,m-2} & a_{m-1,m-1} & a_{m-1,m} \\ 0 & 0 & 0 & 0 & \dots & 0 & a_{m,m-1} & a_{mm} \end{bmatrix},$$

все ненулевые элементы которой расположены на главной и двух соседних с ней диагоналях. Число этих элементов равно  $3m - 2$ , что при большом  $m$  много меньше общего числа  $m^2$  элементов матрицы.

Многие приложения приводят к системам уравнений с так называемыми ленточными матрицами. Матрица  $A$  называется *ленточной* с полушириной ленты, равной  $l$ , если  $a_{ij} = 0$  для  $|i - j| > l$ . Все ненулевые элементы такой матрицы расположены на  $s = 2l + 1$  ближайших к главной диагоналях матрицы; число  $s$  принято называть *шириной ленты*. Схематически ленточная матрица представлена на рис. 5.1. Частным

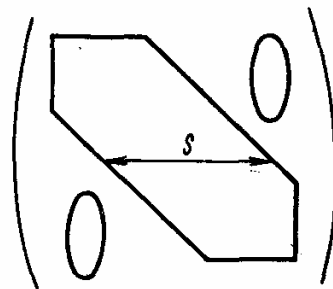


Рис. 5.1

случаем ленточной матрицы при  $s = 3$  является трехдиагональная матрица. Ясно, что в случае  $s \ll m$  ленточная матрица является разреженной.

#### § 5.4. Обусловленность задачи решения системы линейных алгебраических уравнений

Оказывается, что решения различных систем линейных алгебраических уравнений обладают разной чувствительностью к погрешностям входных данных. Так же как и другие задачи (см. § 3.2), задача вычисления решения  $x$  системы уравнений

$$Ax = b \tag{5.18}$$

может быть как хорошо, так и плохо обусловленной.

Исследование обусловленности задачи начнем со случая, когда элементы матрицы  $A$  считаются заданными точно, а вектор-столбец правой части — приближенно.

**Лемма 5.1.** Для погрешности приближенного решения системы (5.18) справедлива оценка



$$\Delta(\mathbf{x}^*) \leq \|A^{-1}\| \cdot \|\mathbf{r}\|, \quad (5.19)$$

где  $\mathbf{r} = \mathbf{b} - A\mathbf{x}^*$  — невязка, отвечающая  $\mathbf{x}^*$ .

Для доказательства достаточно взять норму левой и правой частей равенства (5.3) и воспользоваться свойством (5.10).

**Теорема 5.1.** Пусть  $\mathbf{x}^*$  — точное решение системы  $A\mathbf{x}^* = \mathbf{b}^*$ , в которой правая часть  $\mathbf{b}^*$  является приближением к  $\mathbf{b}$ . Тогда верны следующие оценки абсолютной и относительной погрешностей:

$$\Delta(\mathbf{x}^*) \leq \nu_{\Delta} \Delta(\mathbf{b}^*), \quad (5.20)$$

$$\delta(\mathbf{x}^*) \leq \nu_{\delta} \delta(\mathbf{b}^*), \quad (5.21)$$

где  $\nu_{\Delta} = \|A^{-1}\|$ ,  $\nu_{\delta} = \|A^{-1}\| \cdot \|\mathbf{b}\|/\|\mathbf{x}\|$ .

□ В рассматриваемом случае  $\mathbf{r} = \mathbf{b} - A\mathbf{x}^* = \mathbf{b} - \mathbf{b}^*$  и неравенство (5.19) принимает вид (5.20). Разделив теперь обе части неравенства (5.20) на  $\|\mathbf{x}\|$  и записав его в виде

$$\frac{\Delta(\mathbf{x}^*)}{\|\mathbf{x}\|} \leq \frac{\|A^{-1}\| \cdot \|\mathbf{b}\|}{\|\mathbf{x}\|} \cdot \frac{\Delta(\mathbf{b}^*)}{\|\mathbf{b}\|},$$

приходим к оценке (5.21). ■

**З а м е ч а н и е 1.** Величина  $\nu_{\Delta} = \|A^{-1}\|$  для задачи (5.18) играет роль абсолютного числа обусловленности (см. § 3.2).

**З а м е ч а н и е 2.** Величина  $\nu_{\delta} = \nu_{\delta}(\mathbf{x}) = \|A^{-1}\| \cdot \|\mathbf{b}\|/\|\mathbf{x}\|$  называется *естественным числом обусловленности*. Она зависит от конкретного решения  $\mathbf{x}$  и характеризует коэффициент возможного возрастания относительной погрешности этого решения, вызванного погрешностью задания правой части. Это означает, что  $\nu_{\delta}(\mathbf{x})$  для задачи вычисления решения  $\mathbf{x}$  системы (5.18) играет роль относительного числа обусловленности (см. § 3.2).

**З а м е ч а н и е 3.** Полученные в теореме 5.1 оценки точны в том смысле, что для системы  $A\mathbf{x} = \mathbf{b}$  с произвольной невырожденной матрицей  $A$  и любой заданной правой частью  $\mathbf{b} \neq 0$  найдется сколь угодно близкий к  $\mathbf{b}$  приближенно заданный вектор  $\mathbf{b}^* \neq \mathbf{b}$ , для которого неравенства (5.20) и (5.21) превращаются в равенства.

Вычислим максимальное значение естественного числа обусловленности, используя определение (5.4) нормы матрицы:

$$\max_{\mathbf{x} \neq 0} \nu_{\delta}(\mathbf{x}) = \max_{\mathbf{x} \neq 0} \frac{\|A^{-1}\| \cdot \|A\mathbf{x}\|}{\|\mathbf{x}\|} = \|A^{-1}\| \cdot \|A\|. \quad (5.22)$$

Полученную величину принято называть *стандартным числом обусловленности* (или просто *числом обусловленности*) матрицы  $A$  и обозначать через  $\nu(A)$  или  $\text{cond}(A)$ . Таким образом,

$$\nu(A) = \text{cond}(A) = \|A^{-1}\| \cdot \|A\|. \quad (5.23)$$

Сформулируем важное следствие из теоремы 5.1.

**С л е д с т в и е.** В условиях теоремы 5.1 справедлива оценка

$$\delta(x^*) \leq \text{cond}(A) \cdot \delta(b^*). \quad (5.24)$$

Для ее доказательства достаточно воспользоваться оценкой (5.21) и заметить, что в силу определения (5.22) верно неравенство  $\nu_\delta \leq \text{cond}(A)$ .

**З а м е ч а н и е.** Оценка (5.24) точна в том смысле, что для системы (5.18) с произвольной невырожденной матрицей  $A$  найдутся правая часть  $b \neq 0$  (и отвечающее этой правой части решение  $x$ ) и сколь угодно близкий к  $b$  приближенно заданный вектор  $b^* \neq b$  такие, что неравенство (5.24) превращается в равенство.

Величина  $\text{cond}(A)$  является широко используемой количественной мерой обусловленности системы  $Ax = b$ . В частности, систему и матрицу  $A$  принято называть *плохо обусловленными*, если  $\text{cond}(A) \gg 1$ . В силу оценки (5.24) и последнего замечания для такой системы существуют решения, обладающие чрезвычайно высокой чувствительностью к малым погрешностям задания входного данного  $b$ . Тем не менее заметим, что не для всякого решения  $x$  коэффициент  $\nu_\delta(x)$  роста относительной ошибки достигает значений, близких к максимально возможному значению  $\text{cond}(A)$ .

Отметим следующие свойства числа обусловленности.

1°. Для единичной матрицы  $\text{cond}(E) = 1$ .

□ Пользуясь тем, что  $E^{-1} = E$  и  $\|E\| = 1$  (см. пример 5.3), получим  $\text{cond}(E) = \|E^{-1}\| \cdot \|E\| = 1$ . ■

2°. Справедливо неравенство  $\text{cond}(A) \geq 1$ .

□ Из равенства  $E = A \cdot A^{-1}$ , свойства 4° норм матриц и равенства  $\|E\| = 1$  следует, что  $1 = \|E\| \leq \|A^{-1}\| \cdot \|A\| = \text{cond}(A)$ . ■

3°. Число обусловленности матрицы  $A$  не меняется при умножении матрицы на произвольное число  $\alpha \neq 0$ .

□ Заметим, что  $(\alpha A)^{-1} = \alpha^{-1} A^{-1}$ . Поэтому  $\text{cond}(\alpha A) = \|\alpha A\| \cdot \|(\alpha A)^{-1}\| = |\alpha| \cdot \|A\| \cdot |\alpha|^{-1} \|A^{-1}\| = \text{cond}(A)$ . ■

**З а м е ч а н и е.** Пользуясь приведенной в § 5.2 геометрической интерпретацией норм матриц  $A$  и  $A^{-1}$  (см. формулы (5.15) и (5.16)), число обусловленности можно интерпретировать как отношение

максимального коэффициента растяжения векторов под действием матрицы  $A$  к минимальному коэффициенту:  $\text{cond}(A) = k_{\max}/k_{\min}$ .

Величина  $\text{cond}(A)$  зависит, вообще говоря, от выбора нормы векторов в пространстве  $R^m$ . Фактически это есть зависимость максимального коэффициента роста ошибки от способа измерения величины входных данных и решения. В частности, выбору нормы  $\|x\|_p$  ( $1 \leq p \leq \infty$ ) отвечает  $\text{cond}_p(A) = \|A^{-1}\|_p \cdot \|A\|_p$ .

**Пример 5.4.** Вычислим  $\text{cond}_\infty(A)$  для матрицы

$$A = \begin{bmatrix} 1.03 & 0.991 \\ 0.991 & 0.943 \end{bmatrix}. \quad (5.25)$$

Сначала найдем обратную матрицу

$$A^{-1} \approx \begin{bmatrix} -87.4 & 91.8 \\ 91.8 & -95.4 \end{bmatrix}.$$

Тогда  $\text{cond}_\infty(A) = \|A\|_\infty \cdot \|A^{-1}\|_\infty \approx 2.021 \cdot 187.2 \approx 378$ . Если входные данные для системы уравнений с матрицей (5.25) содержат относительную погрешность порядка 0.1–1%, то систему можно расценить как плохо обусловленную.

**Пример 5.5.** Рассмотрим систему уравнений

$$\begin{aligned} 1.03x_1 + 0.991x_2 &= 2.51, \\ 0.991x_1 + 0.943x_2 &= 2.41 \end{aligned} \quad (5.26)$$

с матрицей (5.25). Ее решением является  $x_1 \approx 1.981$ ,  $x_2 \approx 0.4735$ . Правая часть системы известна в лучшем случае с точностью до 0.005, если считать, что числа 2.51 и 2.41 получены округлением "истинных" значений при вводе в память трехзначной десятичной ЭВМ. Как влияет погрешность во входных данных такого уровня на погрешность решения? Возмутим каждую из компонент вектора правой части  $b = (2.51, 2.41)^T$  на величину 0.005, взяв  $b^* = (2.505, 2.415)^T$ . Решением системы, отвечающим  $b^*$ , является теперь  $x_1^* \approx 2.877$ ,  $x_2^* \approx -0.4629$ . Таким образом, решение оказалось полностью искаженным. Относительная погрешность задания правой части  $\delta(b^*) = \|b - b^*\|_\infty / \|b\|_\infty = 0.005/2.51 \approx 0.2\%$  привела к относительной погрешности решения  $\delta(x^*) = \|x - x^*\|_\infty / \|x\|_\infty \approx 0.9364/1.981 \approx 47.3\%$ . Следовательно, погрешность возросла примерно в 237 раз.

Можно ли ввести в правую часть системы (5.26) такую погрешность, чтобы получить существенно большее, чем 237, значение коэффициента роста ошибки? Вычислим естественное число обусловленности, являющееся максимальным значением рассматриваемого коэффициента, отвечающим решению  $x \approx$

$\approx (1.981, 0.4735)^T$  и получим  $\nu_\delta(x) = \|A^{-1}\|_\infty \|b\|_\infty / \|x\|_\infty \approx 187.2 \cdot 2.51 / 1.981 \approx 237$ .

Таким образом, на поставленный вопрос следует ответить отрицательно.

Можно дать следующую геометрическую интерпретацию рассмотренного примера. Каждому уравнению системы (5.26) соответствует прямая на плоскости  $Ox_1x_2$ . По коэффициентам при  $x_1$  и  $x_2$  в этих уравнениях видно, что прямые почти параллельны. Так как вблизи точки пересечения прямые почти сливаются, то даже незначительная погрешность в задании положения этих прямых существенно меняет положение точки пересечения (рис. 5.2).

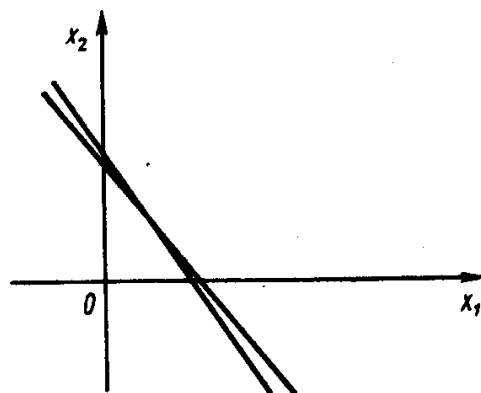


Рис. 5.2

**Пример 5.6.** Традиционным примером очень плохо обусловленной матрицы является матрица Гильберта<sup>1</sup> — матрица  $H$  с элементами  $h_{ij} = 1/(i + j - 1)$ .

Из табл. 5.1, заимствованной из [87], видно, что для матрицы  $H$  даже сравнительно невысокого порядка число обусловленности оказывается чрезвычайно большим.

Т а б л и ц а 5.1

Порядок матрицы Гильберта	2	3	4	5	6	7	8	9	10
Приближенное значение числа обусловленности	$2 \cdot 10^1$	$5 \cdot 10^2$	$2 \cdot 10^4$	$5 \cdot 10^5$	$2 \cdot 10^7$	$5 \cdot 10^8$	$2 \cdot 10^{10}$	$5 \cdot 10^{11}$	$2 \cdot 10^{13}$

До сих пор мы предполагали, что матрица  $A$  задана точно. Однако на практике это часто не так. Как выясняется, введенная выше величина  $\text{cond}(A)$  характеризует также и чувствительность решений системы к малым погрешностям задания элементов матрицы  $A$ . В подтверждение сказанного приведем следующий результат.

**Т е о р е м а 5.2.** Пусть  $x^*$  — точное решение системы  $A_* x^* = b$  с приближенно заданной матрицей  $A_*$ . Тогда верна следующая оценка относительной погрешности:

<sup>1</sup> Давид Гильберт (1862—1943) — немецкий математик, исследования которого оказали большое влияние на развитие современной математики.

$$\delta^*(x^*) \leq \text{cond}(A) \cdot \delta(A_*), \quad (5.27)$$

где  $\delta^*(x^*) = \|x - x^*\|/\|x^*\|$ ,  $\delta(A_*) = \|A - A_*\|/\|A\|$ .

□ В данном случае невязка  $r$  имеет вид  $r = b - Ax^* = A_*x^* - Ax^* = (A_* - A)x^*$ . Применяя неравенство (5.19), получим цепочку неравенств

$$\begin{aligned} \delta^*(x^*) &= \|x - x^*\|/\|x^*\| \leq \|A^{-1}\| \cdot \|(A_* - A)x^*\|/\|x^*\| \leq \\ &\leq \|A^{-1}\| \cdot \|A_* - A\| \cdot \|x^*\|/\|x^*\| = \text{cond}(A) \cdot \delta(A_*). \blacksquare \end{aligned}$$

**С л е д с т в и е.** В условиях теоремы 5.2 справедливо приближенное неравенство

$$\delta(x^*) \lesssim \text{cond}(A) \cdot \delta(A_*). \quad (5.28)$$

**З а м е ч а н и е 1.** В случае, когда с погрешностью заданы как правая часть системы, так и матрица (т. е.  $x^*$  является решением системы  $A_*x^* = b^*$ ), причем  $\text{cond}(A) \cdot \delta(A_*) \ll 1$ , можно доказать справедливость неравенства

$$\delta(x^*) \lesssim \text{cond}(A) (\delta(b^*) + \delta(A_*)).$$

**З а м е ч а н и е 2.** Распространенным является представление о том, что по величине определителя матрицы  $A$  можно судить о степени близости системы уравнений к вырожденной или об обусловленности системы. Для того чтобы убедиться в ошибочности этого мнения, умножим каждое из уравнений системы (5.1) на постоянную  $\alpha \neq 0$ . Ясно, что такое преобразование никак не меняет решение системы и его чувствительность к малым относительным ошибкам в данных. Однако определитель умножается на число  $\alpha^m$ , и поэтому с помощью выбора  $\alpha$  может быть сделан как угодно большим или малым. Подчеркнем, что число обусловленности  $\text{cond}(A)$  при таком преобразовании системы не меняется в силу свойства 3<sup>0</sup>.

**З а м е ч а н и е 3.** Вычисление чисел обусловленности  $\nu_\delta = \|A^{-1}\| \cdot \|b\|/\|x\|$  и  $\text{cond}(A) = \|A^{-1}\| \cdot \|A\|$  непосредственно по указанным формулам предполагает предварительное вычисление обратной матрицы  $A^{-1}$ . Вследствие большой трудоемкости этой операции (как показано в § 5.6, для ее выполнения в общем случае требуется примерно  $2m^3$  арифметических операций) на практике избегают такого способа вычисления. При этом важно отметить, что в большинстве случаев достаточно лишь грубой оценки числа обусловлен-

ности с точностью до порядка. С эффективными методами, дающими оценки величин  $\nu_\delta$  и  $\text{cond}(A)$ , можно познакомиться в [67], [86].

Проверить чувствительность решения системы  $Ax = b$  к погрешностям можно и экспериментально. Для этого достаточно решить задачу несколько раз с несколькими близкими к  $b$  правыми частями  $b^{(1)}$ ,  $b^{(2)}$ , ...,  $b^{(n)}$ . Можно ожидать, что величина  $\tilde{\nu}_\delta = \max_{1 \leq l \leq k} \frac{\delta(x^{(l)})}{\delta(b^{(l)})}$  даст оценку значения  $\nu_\delta$ . Во всяком случае эта величина дает оценку снизу, так как  $\tilde{\nu}_\delta \leq \nu_\delta \leq \text{cond}(A)$ .

## § 5.5 Метод Гаусса

Рассмотрим один из самых распространенных методов решения систем линейных алгебраических уравнений — *метод Гаусса*<sup>1</sup>. Этот метод (который называют также *методом последовательного исключения неизвестных*) известен в различных вариантах уже более 2000 лет.

Вычисления с помощью метода Гаусса состоят из двух основных этапов, называемых *прямым ходом* и *обратным ходом* (*обратной подстановкой*). Прямой ход метода Гаусса заключается в последовательном исключении неизвестных из системы (5.1) для преобразования ее к эквивалентной системе с верхней треугольной матрицей. Вычисления значений неизвестных производят на этапе обратного хода.

**1. Схема единственного деления.** Рассмотрим сначала простейший вариант метода Гаусса, называемый *схемой единственного деления*.

**Прямой ход** состоит из  $m - 1$  шагов исключения.

**1-й шаг.** Целью этого шага является исключение неизвестного  $x_1$  из уравнений с номерами  $i = 2, 3, \dots, m$ . Предположим, что коэффициент  $a_{i1} \neq 0$ . Будем называть его *главным* (или *ведущим*) *элементом 1-го шага*.

Найдем величины

$$\mu_{i1} = a_{i1}/a_{11} \quad (i = 2, 3, \dots, m), \quad (5.29)$$

называемые *множителями 1-го шага*. Вычтем последовательно из второго, третьего, ...,  $m$ -го уравнений системы (5.1) первое уравнение, умноженное соответственно на  $\mu_{21}$ ,  $\mu_{31}$ , ...,  $\mu_{m1}$ . Это позволит обратить в

---

<sup>1</sup> Карл Фридрих Гаусс (1777—1855) — немецкий математик и физик, работы которого оказали большое влияние на дальнейшее развитие высшей алгебры, геометрии, теории чисел, теории электричества и магнетизма.

нуль коэффициенты при  $x_1$  во всех уравнениях, кроме первого. В результате получим эквивалентную систему

[illegible]

в которой  $a_{ij}^{(1)}$  и  $b_i^{(1)}$  ( $i, j = 2, 3, \dots, m$ ) вычисляются по формулам

$$a_{ij}^{(1)} = a_{ij} - \mu_{i1} a_{1j}, \quad b_i^{(1)} = b_i - \mu_{i1} b_1. \quad (5.31)$$

2-й шаг. Целью этого шага является исключение неизвестного  $x_2$  из уравнений с номерами  $i = 3, 4, \dots, m$ . Пусть  $a_{22}^{(1)} \neq 0$ , где  $a_{22}^{(1)}$  — коэффициент, называемый *главным* (или *ведущим*) *элементом* 2-го шага. Вычислим множители 2-го шага

$$\mu_{i2} = a_{i2}^{(1)} / a_{22}^{(1)} \quad (i = 3, 4, \dots, m)$$

и вычтем последовательно из третьего, четвертого, ...,  $m$ -го уравнений системы (5.30) второе уравнение, умноженное соответственно на  $\mu_{32}$ ,  $\mu_{42}$ , ...,  $\mu_{m2}$ . В результате получим систему

[illegible]

Здесь коэффициенты  $a_{ij}^{(2)}$  и  $b_i^{(2)}$  ( $i, j = 3, 4, \dots, m$ ) вычисляются по формулам

$$a_{ij}^{(2)} = a_{ij}^{(1)} - \mu_{i2} a_{2j}^{(1)}, \quad b_i^{(2)} = b_i^{(1)} - \mu_{i2} b_2^{(1)}.$$

Аналогично проводятся остальные шаги. Опишем очередной  $k$ -й шаг.

$k$ -й шаг. В предположении, что главный (ведущий) элемент  $k$ -го шага  $a_{kk}^{(k-1)}$  отличен от нуля, вычислим множители  $k$ -го шага

$$\mu_{ik} = a_{ik}^{(k-1)} / a_{kk}^{(k-1)} \quad (i = k + 1, \dots, m)$$

и вычтем последовательно из  $(k + 1)$ -го, ...,  $m$ -го уравнений полученной на предыдущем шаге системы  $k$ -е уравнение, умноженное соответственно на  $\mu_{k+1,k}$ ,  $\mu_{k+2,k}$ , ...,  $\mu_{mk}$ .

После  $(m - 1)$ -го шага исключения получим систему уравнений

[illegible]

матрица  $A^{(m-1)}$  которой является верхней треугольной. На этом вычисления прямого хода заканчиваются.

Обратный ход. Из последнего уравнения системы (5.33) находим  $x_m$ . Подставляя найденное значение  $x_m$  в предпоследнее уравнение, получим  $x_{m-1}$ . Осуществляя обратную подстановку, далее последовательно находим  $x_{m-2}$ ,  $x_{m-3}$ , ...,  $x_1$ . Вычисления неизвестных здесь проводятся по формулам

$$\begin{aligned} x_m &= b_m^{(m-1)} / a_{mm}^{(m-1)}, \\ x_k &= (b_k^{(k-1)} - a_{kk}^{(k-1)} x_{k+1} - \dots - a_{km}^{(k-1)} x_m) / a_{kk}^{(k-1)}, \quad (k = m-1, \dots, 1). \end{aligned} \quad (5.34)$$

**Трудоемкость метода.** Оценим число арифметических операций, необходимых для реализации схемы единственного деления.

Вычисления 1-го шага исключения по формулам (5.29), (5.31) требуют выполнения  $m - 1$  деления,  $(m - 1)m$  умножений и  $(m - 1)m$  вычитаний, т. е. общее число арифметических операций составляет  $Q_1 = 2(m - 1)^2 + 3(m - 1)$ . Аналогично, на 2-м шаге требуется  $Q_2 = 2(m - 2)^2 + 3(m - 2)$  операций, а на  $k$ -м шаге —  $Q_k = 2(m - k)^2 + 3(m - k)$  операций.

Подсчитаем теперь приближенно общее число  $Q$  арифметических операций прямого хода, считая размерность системы  $m$  достаточно большой:

$$Q = \sum_{k=1}^{m-1} Q_k = 2 \sum_{k=1}^{m-1} (m-k)^2 + 3 \sum_{k=1}^{m-1} (m-k) = 2 \sum_{k=1}^{m-1} k^2 + 3 \sum_{k=1}^{m-1} k =$$

$$= \frac{2(m-1)m(2m-1)}{6} + \frac{3(m-1)m}{2} \approx \frac{2}{3} m^3.$$



Как нетрудно видеть, для реализации обратного хода по формулам (5.34) нужно всего  $m^2$  операций, что при больших  $m$  пренебрежимо мало по сравнению с числом операций прямого хода.

Таким образом, для реализации метода Гаусса требуется примерно  $(2/3)m^3$  арифметических операций, причем подавляющее число этих действий совершается на этапе прямого хода.

**Пример 5.7.** Методом Гаусса решим систему

$$\begin{aligned} 10x_1 + 6x_2 + 2x_3 &= 25, \\ 5x_1 + x_2 - 2x_3 + 4x_4 &= 14, \\ 3x_1 + 5x_2 + x_3 - x_4 &= 10, \\ 6x_2 - 2x_3 + 2x_4 &= 8. \end{aligned} \quad (5.35)$$

**Прямой ход.** 1-й шаг. Вычислим множители  $\mu_{21} = a_{21}/a_{11} = 5/10 = 0.5$ ,  $\mu_{31} = a_{31}/a_{11} = 3/10 = 0.3$ ,  $\mu_{41} = a_{41}/a_{11} = 0/10 = 0$ . Вычитая из второго, третьего и четвертого уравнений системы (5.35) первое уравнение, умноженное на  $\mu_{21}$ ,  $\mu_{31}$  и  $\mu_{41}$  соответственно получим

$$\begin{aligned} 10x_1 + 6x_2 + 2x_3 &= 25, \\ -2x_2 - 3x_3 + 4x_4 &= 1.5, \\ 3.2x_2 + 0.4x_3 - x_4 &= 2.5, \\ 6x_2 - 2x_3 + 2x_4 &= 8. \end{aligned} \quad (5.36)$$

2-й шаг. Вычислим множители  $\mu_{32} = a_{32}^{(1)}/a_{22}^{(1)} = 3.2/(-2) = -1.6$ ,  $\mu_{42} = 6/(-2) = -3$ . Вычитая из третьего и четвертого уравнений системы (5.36) второе уравнение, умноженное на  $\mu_{32}$  и  $\mu_{42}$  соответственно, приходим к системе

$$\begin{aligned} 10x_1 + 6x_2 + 2x_3 &= 25, \\ -2x_2 - 3x_3 + 4x_4 &= 1.5, \\ -4.4x_3 + 5.4x_4 &= 4.9, \\ -11x_3 + 14x_4 &= 12.5. \end{aligned} \quad (5.37)$$

3-й шаг. Вычисляя множитель  $\mu_{43} = (-11)/(-4.4) = 2.5$  и вычитая из четвертого уравнения системы (5.37) третье уравнение, умноженное на  $\mu_{43}$ , приводим систему к треугольному виду:

$$\begin{aligned} 10x_1 + 6x_2 + 2x_3 &= 25, \\ -2x_2 - 3x_3 + 4x_4 &= 1.5, \\ -4.4x_3 + 5.4x_4 &= 4.9, \\ 0.5x_4 &= 0.25. \end{aligned} \quad (5.38)$$

**Обратный ход.** Из последнего уравнения системы находим  $x_4 = 0.5$ . Подставляя значение  $x_4$  в третье уравнение, находим  $x_3 =$

$= (4.9 - 5.4x_4)/(-4.4) = -0.5$ . Продолжая далее обратную подстановку, получаем  $x_2 = (1.5 + 3x_3 - 4x_4)/(-2) = 1$ ,  $x_1 = (25 - 6x_2 - 2x_3)/10 = 2$ . Итак,  $x_1 = 2$ ,  $x_2 = 1$ ,  $x_3 = -0.5$ ,  $x_4 = 0.5$ .

Результаты вычислений можно свести в следующую таблицу.

Т а б л и ц а 5.2

	$a_{i1}$	$a_{i2}$	$a_{i3}$	$a_{i4}$	$b_i$	$\mu_{ij}, x_i$
Исходная система	10	6	2	0	25	
	5	1	-2	4	14	
	3	5	1	-1	10	
	0	6	-2	2	8	
1-й шаг прямого хода	10	6	2	0	25	
	0	-2	-3	4	1.5	0.5
	0	3.2	0.4	-1	2.5	0.3
	0	6	-2	2	8	0
2-й шаг прямого хода	10	6	2	0	25	
	0	-2	-3	4	1.5	
	0	0	-4.4	5.4	4.9	-1.6
	0	0	-11	14	7.5	-3
3-й шаг прямого хода и обратный ход	10	6	2	0	25	2
	0	-2	-3	4	1.5	1
	0	0	-4.4	5.4	4.9	-0.5
	0	0	0	0.5	0.25	0.5

Необходимость выбора главных элементов. Заметим, что вычисление множителей, а также обратная подстановка требуют деления на главные элементы  $a_{kk}^{(k-1)}$ . Поэтому если один из главных элементов сказывается равным нулю, то схема единственного деления не может быть реализована. Здравый смысл подсказывает, что и в ситуации, когда все главные элементы отличны от нуля, но среди них есть близкие к нулю, возможен неконтролируемый рост погрешности.

**Пример 5.8.** Используя метод Гаусса, решим систему уравнений

$$\begin{aligned} 2x_1 - 9x_2 + 5x_3 &= -4, \\ 1.2x_1 - 5.3999x_2 + 6x_3 &= 0.6001, \\ x_1 - x_2 - 7.5x_3 &= -8.5 \end{aligned} \quad (5.39)$$

на 6-разрядной десятичной ЭВМ.

Прямой ход. 1-й шаг. Вычисляем множители  $\mu_{21} = 0.6$  и  $\mu_{31} = 0.5$  и преобразуем систему к виду

$$\begin{aligned} 2x_1 - 9x_2 + 5x_3 &= -4, \\ 0.0001x_2 + 3x_3 &= 3.0001, \\ 3.5x_2 - 10x_3 &= -6.5. \end{aligned} \quad (5.40)$$

Все вычисления на этом шаге выполняются без округлений.

2-й шаг. После вычисления множителя  $\mu_{32} = 3.5/0.0001 = 35\,000$  последнее уравнение системы должно быть преобразовано к виду  $a_{33}^{(2)}x_3 = b_3^{(2)}$ , где  $a_{33}^{(2)} = -10 - 3 \cdot \mu_{32} = -105010$ ,  $b_3^{(2)} = -6.5 - 3.0001 \cdot \mu_{32} = -105010$ . Однако на используемой ЭВМ будет получено уравнение

$$-105010x_3 = -105011. \quad (5.41)$$

Действительно, коэффициент  $a_{33}^{(2)}$  определяется точно, так как при его вычислении не возникает чисел, мантиссы которых имеют более 6 разрядов. В то же время при вычислении  $b_3^{(2)}$  умножение коэффициента 3.0001 на  $\mu_{32}$  дает 7-разрядное число 105003.5, после округления которого до 6 разрядов получится 105004. Вычисление  $b_3^{(2)}$  завершается выполнением операции вычитания:  $b_3^{(2)} \approx -6.5 - 105004 = -105010.5$ . После округления последнего числа до 6 разрядов мантиссы приходим к уравнению (5.41).

Обратный ход. Из уравнения (5.41) находим  $x_3 \approx 1.00001$ . Сравнение с истинным значением  $x_3 = 1$  показывает, что эта величина получена с очень высокой для используемой ЭВМ точностью.

Дальнейшие вычисления дают

$$\begin{aligned} x_2 &= (3.0001 - 3x_3)/0.0001 = (3.0001 - 3.00003)/0.0001 = 0.7, \\ x_1 &= (-4 + 9x_2 - 5x_3)/2 = (-4 + 6.3 - 5.00005)/2 = -1.350025. \end{aligned}$$

После округления имеем  $x_1 = -1.35003$ .

Как нетрудно видеть, найденные значения неизвестных имеют мало общего с истинными значениями решения  $x_1 = 0$ ,  $x_2 = 1$ ,  $x_3 = 1$ .

В чем же причина появления такой значительной погрешности? Говорить о накоплении ошибок округления не приходится, так как всего было выполнено 28 арифметических операций и лишь в 4 случаях потребовалось округление. Предположение о плохой обусловленности системы не подтверждается; вычисление  $\text{cond}_\infty(A)$  дает значение  $\approx 100$ .

В действительности причина состоит в использовании на 2-м шаге малого ведущего элемента  $a_{22}^{(2)} = 0.0001$ . Следствием этого стало появление большого

множителя  $\mu_{32}$  и существенное возрастание коэффициента в последнем уравнении системы.

Таким образом, изложенный выше вариант метода Гаусса (схема единственного деления) оказался некорректным и, следовательно, непригодным для вычислений на ЭВМ. Этот метод может привести к аварийному останову (если  $a_{kk}^{(k-1)} = 0$  при некотором  $k$ ), и вычисления по нему могут оказаться неустойчивыми.

**2. Метод Гаусса с выбором главного элемента по столбцу (схема частичного выбора).** О п и с а н и е м е т о д а. На  $k$ -м шаге прямого хода коэффициенты уравнений системы с номерами  $i = k + 1, \dots, m$  преобразуются по формулам

$$a_{ij}^{(k)} = a_{ij}^{(k-1)} - \mu_{ik} a_{kj}^{(k-1)}, \quad b_i^{(k)} = b_i^{(k-1)} - \mu_{ik} b_k^{(k-1)}, \quad i = k + 1, \dots, m. \quad (5.42)$$

Интуитивно ясно, что во избежание сильного роста коэффициентов системы и связанных с этим ошибок нельзя допускать появления больших множителей  $\mu_{ik}$ .

В методе Гаусса с выбором главного элемента по столбцу гарантируется, что  $|\mu_{ik}| \leq 1$  для всех  $k = 1, 2, \dots, m - 1$  и  $i = k + 1, \dots, m$ . Отличие этого варианта метода Гаусса от схемы единственного деления заключается в том, что на  $k$ -м шаге исключения в качестве главного элемента выбирают максимальный по модулю коэффициент  $a_{i,k}$  при неизвестной  $x_k$  в уравнениях с номерами  $i = k, k + 1, \dots, m$ . Затем соответствующее выбранному коэффициенту уравнение с номером  $i_k$  меняют местами с  $k$ -м уравнением системы для того, чтобы главный элемент занял место коэффициента  $a_{kk}^{(k-1)}$ .

После этой перестановки исключение неизвестного  $x_k$  производят, как в схеме единственного деления.

**Пример 5.9.** Решим систему уравнений (5.39) методом Гаусса с выбором главного элемента по столбцу на 6-разрядной десятичной ЭВМ.

**П р я м о й х о д.** 1-й шаг. Максимальный в первом столбце элемент матрицы находится в первой строке, поэтому перестановка уравнений не нужна. Здесь 1-й шаг проводится точно так же, как и в примере 5.8.

2-й шаг. Среди элементов  $a_{22}^{(1)} = 0.0001$  и  $a_{32}^{(1)} = 3.5$  матрицы системы (5.40) максимальный принадлежит третьему уравнению. Меняя местами второе и третье уравнения, получим систему

$$\begin{aligned} 2x_1 - 9x_2 + 5x_3 &= -4, \\ 3.5x_2 - 10x_3 &= -6.5, \\ 0.0001x_2 + 3x_3 &= 3.0001. \end{aligned}$$

После вычисления  $\mu_{32} = 0.0001/3.5 \approx 2.85714 \cdot 10^{-5}$  последнее уравнение системы преобразуется к виду  $3.00029x_3 = 3.00029$ .

Обратный ход. Из последнего уравнения находим  $x_3 = 1$ . Далее, имеем  $x_2 = (-6.5 + 10x_3)/3.5 = 1$ ,  $x_1 = (-4 + 9x_2 - 5x_3)/2 = (-4 + 9 - 5)/2 = 0$ . В данном случае ответ получился точным.

Заметим, что дополнительная работа по выбору главных элементов в схеме частичного выбора требует порядка  $m^2$  действий, что практически не влияет на общую трудоемкость метода.

Вычислительная устойчивость схемы частичного выбора. Детальное исследование метода Гаусса показывает, что действительной причиной неустойчивости схемы единственного деления является возможность неограниченного роста элементов промежуточных матриц  $A^{(1)}, A^{(2)}, \dots, A^{(m-1)}$  в процессе прямого хода. Так как на  $k$ -м шаге схемы частичного выбора  $|\mu_{ik}| \leq 1$ , то для вычисленных по формулам (5.42) элементов  $a_{ij}^{(k)}$  справедлива оценка  $|a_{ij}^{(k)}| \leq |a_{ij}^{(k-1)}| + |a_{kj}^{(k-1)}|$ . Следовательно, максимальное по модулю значение элементов матрицы возрастает на одном шаге не более чем в 2 раза и в самом неблагоприятном случае  $m - 1$  шаг прямого хода даст коэффициент роста  $\varphi(m) = 2^{m-1}$ .

Гарантия ограниченности роста элементов матрицы делает схему частичного выбора вычислительно устойчивой. Более того, для нее оказывается справедливой следующая оценка погрешности:

$$\delta(x^*) \leq f(m) \operatorname{cond}_E(A) \cdot \varepsilon_M. \quad (5.43)$$

Здесь  $x^*$  — вычисленное на ЭВМ решение системы;  $\delta(x^*) = \|x - x^*\|_2 / \|x\|_2$  — его относительная погрешность;  $\operatorname{cond}_E(A) = \|A\|_E \|A^{-1}\|_E$  — число обусловленности матрицы  $A$ ;  $\varepsilon_M$  — машинное эпсилон; наконец,  $f(m) = C(m) \varphi(m)$ , причем  $C(m)$  — некоторая медленно растущая функция, зависящая от порядка  $m$  системы (типа степенной функции с небольшим показателем),  $\varphi(m)$  — коэффициент роста.

Наличие в оценке (5.43) множителя  $\varphi(m) = 2^{m-1}$  указывает на то, что при большом  $m$  схема частичного выбора может оказаться плохо обусловленной и возможна существенная потеря точности. Однако практика матричных вычислений показывает, что существенный рост элементов матрицы происходит крайне редко. В подавляющем большинстве случаев действительное значение коэффициента роста не превышает 8—10. Если система хорошо обусловлена, то погрешность вычисленного решения оказывается, как правило, малой.

Иногда для проверки качества приближенного решения  $x^*$  вычис-

ляют невязку  $r = b - Ax^*$  и о степени близости приближенного решения к точному пытаются судить по тому, насколько мала невязка. Этот метод ненадежен по отношению к схеме частичного выбора, так как известно, что она гарантированно дает малые невязки. Более точно это утверждение можно сформулировать так: справедлива оценка

$$\|r\|_2 \leq f(m) \|A\|_E \|x\|_2 \varepsilon_m, \quad (5.44)$$

где  $f(m)$  то же, что и в оценке (5.43). Заметим, что в неравенство (5.44) не входит число обусловленности.

**3. Метод Гаусса с выбором главного элемента по всей матрице (схема полного выбора).** В этой схеме допускается нарушение естественного порядка исключения неизвестных.

На 1-м шаге метода среди элементов  $a_{ij}$  определяют максимальный по модулю элемент  $a_{i_1 j_1}$ . Первое уравнение системы и уравнение с номером  $i_1$  меняют местами. Далее стандартным образом производят исключение неизвестного  $x_{j_1}$  из всех уравнений, кроме первого.

На  $k$ -м шаге метода среди коэффициентов  $a_{ij}^{(k-1)}$  при неизвестных в уравнениях системы с номерами  $i = k, \dots, m$  выбирают максимальный по модулю коэффициент  $a_{i k j_k}^{(k-1)}$ . Затем  $k$ -е уравнение и уравнение, содержащее найденный коэффициент, меняют местами и исключают неизвестное  $x_{j_k}$  из уравнений с номерами  $i = k + 1, \dots, m$ .

На этапе обратного хода неизвестные вычисляют в следующем порядке:  $x_{j_m}, x_{j_{m-1}}, \dots, x_{j_1}$ .

**Пример 5.10.** Решим систему (5.39), используя схему полного выбора на 6-разрядной десятичной ЭВМ.

**П р я м о й х о д.** 1-й шаг. Максимальный по модулю элемент  $a_{12} = -9$  содержится в первом уравнении, поэтому перестановка уравнений не нужна. Исключаем неизвестное  $x_2$  из второго и третьего уравнений, и используя множители  $\mu_{21} = -5.3999/(-9) \approx 0.599989$  и  $\mu_{31} = -1/(-9) \approx 0.111111$ . В результате получим систему

$$\begin{array}{rcl} 2x_1 - & 9x_2 + & 5x_3 = -4, \\ 2.2 \cdot 10^{-5}x_1 & + 3.00006x_3 = 3.00006, \\ 0.777778x_1 & - 8.05556x_3 = -8.05556. \end{array}$$

2-й шаг. Среди коэффициентов при неизвестных во втором и третьем уравнениях максимальным является коэффициент  $a_{33}^{(1)} = -8.05556$ . Перестав-

для местами второе и третье уравнения и исключая неизвестное  $x_3$  (соответствующий множитель  $\mu_{32} = 3.00006/(-8.05556) \approx -0.372421$ ), приходим к системе

$$\begin{array}{rcl} 2x_1 - & 9x_2 + & 5x_3 = -4, \\ 0.777778x_1 & - 8.05556x_3 = & -8.05556, \\ 0.289683x_1 & & = 2.89240 \cdot 10^{-7}. \end{array}$$

Обратный ход. Из последнего уравнения находим  $x_1 = 2.89240 \cdot 10^{-7} / 0.289683 \approx 9.98470 \cdot 10^{-7}$ . Далее, имеем  $x_3 = (-8.05556 - 0.777778x_1) / (-8.05556) \approx 1.00000$ ,  $x_2 = (-4 - 2x_1 - 5x_3) / (-9) = 1.00000$ .

Округляя найденные значения до пяти цифр после десятичной точки, получим ответ:  $x_1 = 0.00000$ ,  $x_2 = 1.00000$ ,  $x_3 = 1.00000$ . Заметим, что в данном случае получено решение, совпадающее с точным.

Схема полного выбора по сравнению со схемой частичного выбора дает существенное замедление роста элементов матрицы. Доказано, что для нее коэффициент роста  $\varphi(m)$ , входящий в оценку (5.43), не превышает величины  $m^{1/2} (2^{1/2} \cdot 3^{1/2} \cdot 4^{1/3} \dots m^{1/(m-1)})^{1/2} \leq 1.8m^{0.25 \ln m}$  (что значительно меньше соответствующего значения  $\varphi(m) = 2^{m-1}$  для схемы частичного выбора). Подчеркнем, что до сих пор еще не найдено матрицы, для которой полный выбор дал бы значение  $\varphi(m) > m$ . Таким образом, для хорошо обусловленных систем этот вариант метода Гаусса является хорошо обусловленным.

Однако гарантия хорошей обусловленности достигается здесь ценой значительных затрат на выбор главных элементов. Для этого дополнительно к  $(2/3)m^3$  арифметических действий требуется произвести примерно  $m^3/3$  операций сравнения, что может ощутимо замедлить процесс решения задачи на ЭВМ. Поэтому в большинстве случаев на практике предпочтение отдается все же схеме частичного выбора. Как уже отмечено, ситуации, когда при использовании этого варианта метода Гаусса происходит существенный рост элементов, встречаются чрезвычайно редко. Более того, эти ситуации могут быть легко выявлены с помощью заложенных в современных программах эффективных методов слежения за ростом элементов матриц.

**4. Случай, когда выбор главных элементов не нужен.** Известно, что для некоторых классов матриц при использовании схемы единственного деления главные элементы гарантированно располагаются на главной диагонали и потому применять частичный выбор нет необходимости. Так, например, обстоит дело для систем с положительно определенными матрицами, а также с матрицами, обладающими следующим свойством диагонального преобладания:

$$\sum_{\substack{j=1 \\ j \neq i}}^m |a_{ij}| < |a_{ii}|, \quad i = 1, 2, \dots, m. \quad (5.45)$$

Матрицы, удовлетворяющие условию (5.45), таковы, что в каждой из строк модуль элемента  $a_{ii}$ , расположенного на главной диагонали, больше суммы модулей всех остальных элементов строки.

**5. Масштабирование.** Перед началом решения целесообразно масштабировать систему так, чтобы ее коэффициенты были величинами порядка единицы.

Существуют два естественных способа масштабирования системы  $Ax = b$ . Первый заключается в умножении каждого из уравнений на некоторый масштабирующий множитель  $\mu_i$ . Второй состоит в умножении на масштабирующий множитель  $\alpha_j$  каждого  $j$ -го столбца матрицы, что соответствует замене переменных  $x'_j = \alpha_j^{-1} x_j$  (фактически — это замена единиц измерения). В реальных ситуациях чаще всего масштабирование может быть выполнено без существенных трудностей. Однако подчеркнем, что в общем случае удовлетворительного способа масштабирования пока не найдено.

На практике масштабирование обычно производят с помощью деления каждого уравнения на его наибольший по модулю коэффициент. Это вполне удовлетворительный способ для большинства реально встречающихся задач.

### § 5.6. Метод Гаусса и решение систем уравнений с несколькими правыми частями, обращение матриц, вычисление определителей

Рассмотрим применение метода Гаусса к решению следующих задач линейной алгебры: 1) вычисление решений системы уравнений с несколькими правыми частями; 2) вычисление обратной матрицы; 3) вычисление определителя.

**1. Вычисление решений системы уравнений с несколькими правыми частями.** Довольно часто на практике встречается ситуация, когда нужно решить несколько систем уравнений

$$Ax = d_{(1)}, \quad Ax = d_{(2)}, \quad \dots, \quad Ax = d_{(p)} \quad (5.46)$$

с одной матрицей  $A$  и различными правыми частями  $d_{(1)}, d_{(2)}, \dots, d_{(p)}$ .

Конечно, применяя метод Гаусса к каждой из систем (5.46) независимо от других, можно найти соответствующие решения  $x_{(1)}, x_{(2)}, \dots,$



$\mathbf{x}_{(p)}$ , затратив примерно  $(2/3)pt^3$  арифметических операций. Однако при одновременном решении систем (5.46) число операций можно существенно сократить. Как было отмечено в § 5.5, основные вычислительные затраты в методе Гаусса связаны с преобразованием матрицы к треугольному виду. Преобразование же правой части производится параллельно и требует примерно  $mt^2$  арифметических операций. Если параллельно с приведением матрицы  $A$  к треугольному виду преобразовать по однотипным формулам все  $p$  правых частей, то на прямой ход метода будет затрачено только примерно  $(2/3)t^3 + pt^2$  операций. С учетом обратного хода общие вычислительные затраты составят примерно  $(2/3)t^3 + 2pt^2$  арифметических операций.

Преобразование правых частей не обязательно производить параллельно. Каждую из правых частей  $\mathbf{d}_{(1)}, \mathbf{d}_{(2)}, \dots, \mathbf{d}_{(p)}$  можно обработать последовательно, если после приведения матрицы  $A$  к треугольному виду  $A^{(m-1)}$  сохранить в памяти ЭВМ множители  $\mu_{ij}$  и матрицу  $A^{(m-1)}$ .

**2. Вычисление обратной матрицы.** Прежде чем переходить к изложению метода вычисления обратной матрицы  $A^{-1}$  для квадратной невырожденной матрицы  $A$ , отметим, что в действительности проблема вычисления обратной матрицы возникает не так часто, как это можно предполагать.

К сожалению, зачастую обращение матрицы  $A$  производится с единственной целью вычислить по известному вектору  $\mathbf{b}$  вектор  $\mathbf{x}$  вида  $\mathbf{x} = A^{-1}\mathbf{b}$ . Умножение матрицы  $A^{-1}$  на вектор требует примерно  $2mt^2$  арифметических операций. Однако вычисление  $A^{-1}$  обходится (как будет показано ниже) примерно в  $2mt^3$  операций. Это означает, что на вычисление решения системы  $A\mathbf{x} = \mathbf{b}$  по формуле  $\mathbf{x} = A^{-1}\mathbf{b}$  будет затрачено примерно  $2mt^3$  операций. В данном случае  $\mathbf{x}$  можно найти в 3 раза быстрее методом Гаусса и вычисление  $A^{-1}$  не нужно. Более того, можно ожидать, что вычисленное методом Гаусса решение окажется точнее, так как потребуются выполнение меньшего числа операций.

Может показаться особенно выгодным предварительное вычисление матрицы  $A^{-1}$ , если далее потребуется найти большое число векторов по формулам

$$\mathbf{x}_{(1)} = A^{-1}\mathbf{d}_{(1)}, \mathbf{x}_{(2)} = A^{-1}\mathbf{d}_{(2)}, \dots, \mathbf{x}_{(p)} = A^{-1}\mathbf{d}_{(p)}. \quad (5.47)$$

Однако суммарные затраты при таком подходе составят примерно  $2mt^3 + 2pt^2$  операций, в то время как при одновременном решении методом Гаусса эквивалентной системы (5.46) получаем значения  $\mathbf{x}_{(1)}, \mathbf{x}_{(2)}, \dots, \mathbf{x}_{(p)}$  примерно за  $(2/3)t^3 + 2pt^2$  операций. Следовательно, и в этом случае вычисление  $A^{-1}$  нецелесообразно.

Иногда в пользу необходимости вычисления  $A^{-1}$  приводится следующий довод. Если известно, что в течение длительного времени потребуется неоднократно решать системы уравнений вида (5.46) с фиксированной матрицей  $A$  и различными правыми частями  $d_{(k)}$ , то имеет смысл предварительно вычислить  $A^{-1}$ . Записав  $A^{-1}$  в память ЭВМ, можно затем по мере необходимости быстро вычислять  $x_{(k)}$  по формуле  $x_{(k)} = A^{-1}d_{(k)}$ . Однако использование  $LU$ -разложения матрицы  $A$  (см. § 5.7) позволяет вычислять  $x_{(k)}$  столь же быстро, а предварительная работа на этапе разложения дает трехкратную экономию. Таким образом, и этот довод в пользу необходимости вычисления обратной матрицы неубедителен.

Довольно часто при решении различных задач средствами линейной алгебры возникают выражения типа

$$v = B^{-1}CA^{-1}WD^{-1}w. \quad (5.48)$$

Если у исследователя нет достаточного опыта решения задач линейной алгебры на ЭВМ, то он может принять решение о необходимости вычислять матрицы  $B^{-1}$ ,  $A^{-1}$ ,  $D^{-1}$ , с тем чтобы действовать далее по формуле (5.48). Однако и в этом случае можно поступить иначе и найти  $v$  с меньшими затратами. Решая систему  $Dx = w$ , найдем  $x = D^{-1}w$ . Затем вычислим  $y = Wx$  и, решая систему  $Az = y$ , найдем  $z = A^{-1}y$ . Наконец, вычислим  $u = Cz$  и, решая систему  $Bv = u$ , найдем  $v = B^{-1}u$ .

Сказанное выше вовсе не означает, что нет ситуаций, когда вычисление матрицы  $A^{-1}$  необходимо и оправдано. В ряде технических приложений и статистических задач непосредственный интерес представляет анализ свойств именно обратной матрицы. Тем не менее, как мы видим, в матричных вычислениях можно и следует обходиться без вычисления обратных матриц. Авторы настоятельно рекомендуют не вычислять обратные матрицы, если только в дальнейшем не предполагается анализ элементов этих матриц.

Покажем, как вычисление обратной матрицы можно свести к рассмотренной выше задаче решения системы уравнений с несколькими правыми частями. Обозначим матрицу  $A^{-1}$  через  $V$ , ее столбцы — через  $v_1, v_2, \dots, v_m$  и столбцы единичной матрицы  $E$  — через  $e_1, e_2, \dots, e_m$ .

Согласно определению обратной матрицы верно равенство  $AV = E$ , эквивалентное совокупности равенств

$$Av_1 = e_1, Av_2 = e_2, \dots, Av_m = e_m. \quad (5.49)$$

Таким образом, столбцы матрицы  $V = A^{-1}$  (а следовательно, и саму матрицу), можно найти, решая  $m$  систем уравнений с общей матрицей

А. Согласно изложенному выше, для этого потребовалось бы примерно  $(8/3)m^3$  арифметических операций, однако учет специального вида правых частей системы (5.49) позволяет вычислять матрицу  $A^{-1}$  примерно за  $2m^3$  операций.

**3. Вычисление определителя.** Воспользуемся алгоритмом метода Гаусса с выбором главного элемента по столбцу и заметим, что иско-мый определитель и определитель полученной треугольной матрицы  $A^{(m-1)}$  связаны равенством

$$\det A = (-1)^s \det A^{(m-1)},$$

где  $s$  — число потребовавшихся перестановок строк. Остается воспользо-ваться формулой (5.17) и тогда получим

$$\det A = (-1)^s a_{11}^{(0)} a_{22}^{(1)} \dots a_{mm}^{(m-1)}, \quad (5.50)$$

где  $a_{11}^{(0)} = a_{11}$ . Отметим, что вычисление по формуле (5.50) требует особой аккуратности, в особенности если число  $m$  велико. Как мы убедились в примере 3.29, при вычислении произведений следует специальным образом упорядочивать сомножители. Неудачный поряд-ок их расположения может привести к аварийному останову по пере-полнению либо к исчезновению порядка.

Можно избежать переполнения и исчезновения порядка, если для вычисления  $\det A$  воспользоваться формулой

$$\ln |\det A| = \sum_{i=1}^m \ln |a_{ii}^{(i-1)}|.$$

Однако следует иметь в виду, что ее использование может привести к некоторой потере точности.

**З а м е ч а н и е.** Действительная необходимость в вычислении определителей возникает довольно редко. Во всяком случае осно-ванные на их использовании алгоритмы оказываются весьма неэф-фективными (как в примере 3.34, где обсуждалось правило Краме-ра), и поэтому вычисление определителей давно уже не является элементом современных алгоритмов линейной алгебры. Кроме того, из результатов в § 5.4 следует, что использование величины  $\det A$  для определения степени близости системы уравнений к вырожден-ной дает весьма ненадежный и сомнительный критерий.

**Пример 5.11.** Используя метод Гаусса с выбором главного элемента по столбцу вычислим определитель матрицы

$$A = \begin{bmatrix} 2 & -9 & 5 \\ 1.2 & -5.3999 & 6 \\ 1 & -1 & -7.5 \end{bmatrix}$$

на 6-разрядной десятичной ЭВМ.

Повторяя преобразования из примера 5.9, получим матрицу

$$A^{(2)} = \begin{bmatrix} 2 & -9 & 5 \\ 0 & 3.5 & -10 \\ 0 & 0 & 3.00029 \end{bmatrix}.$$

Так как была сделана одна перестановка строк, то формула (5.50) дает  $\det(A) \approx (-1) \cdot 2 \cdot 3.5 \cdot 3.00029 \approx -21.0020$ .

Можно с достаточной степенью уверенности предположить, что во многих технических науках, где традиционно используются определители, в ближайшее время неизбежен переход к использованию других более содержательных характеристик линейных моделей. Такими естественными характеристиками могут служить, например, собственные числа и собственные векторы матриц (см. гл. 8).

## § 5.7. Метод Гаусса

и разложение матрицы на множители.

*LU-разложение*

Вернемся еще раз к методу Гаусса с тем, чтобы рассмотреть его с более общих позиций. Излагаемый ниже подход оказался чрезвычайно плодотворным и привел не только к более глубокому пониманию метода, но и позволил создать высокоэффективные машинные алгоритмы его реализации, а также рассматривать другие точные методы с единой точки зрения.

Рассмотрим сначала простейший вариант метода Гаусса для решения системы линейных алгебраических уравнений

$$Ax = b. \quad (5.51)$$

1. *Схема единственного деления и LU-разложение.* При выполнении вычислений 1-го шага исключения по схеме единственного деления система уравнений приводится к виду

$$A^{(1)}x = b^{(1)}, \quad (5.52)$$

где

$$A^{(1)} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1m} \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} & \dots & a_{2m}^{(1)} \\ 0 & a_{32}^{(1)} & a_{33}^{(1)} & \dots & a_{3m}^{(1)} \\ \dots & \dots & \dots & \dots & \dots \\ 0 & a_{m2}^{(1)} & a_{m3}^{(1)} & \dots & a_{mm}^{(1)} \end{bmatrix}, \quad b^{(1)} = \begin{bmatrix} b_1 \\ b_2^{(1)} \\ b_3^{(1)} \\ \vdots \\ b_m^{(1)} \end{bmatrix},$$

а коэффициенты  $a_{ij}^{(1)}$ ,  $b_i^{(1)}$  ( $i, j = 2, 3, \dots, m$ ) вычисляются по формулам (5.29), (5.31).

Введем матрицу

$$M_1 = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ -\mu_{21} & 1 & 0 & \dots & 0 \\ -\mu_{31} & 0 & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ -\mu_{m1} & 0 & 0 & \dots & 1 \end{bmatrix}.$$

Как нетрудно проверить, справедливы равенства

$$A^{(1)} = M_1 A, \quad b^{(1)} = M_1 b,$$

т. е. преобразование системы (5.51) к виду (5.52) эквивалентно умножению левой и правой частей системы на матрицу  $M_1$ .

Аналогично можно показать, что вычисления 2-го шага исключения приводят систему (5.52) к виду

$$A^{(2)} x = b^{(2)},$$

где

$$A^{(2)} = M_2 A^{(1)}, \quad b^{(2)} = M_2 b^{(1)},$$

$$A^{(2)} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1m} \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} & \dots & a_{2m}^{(1)} \\ 0 & 0 & a_{33}^{(2)} & \dots & a_{3m}^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & a_{m3}^{(2)} & \dots & a_{mm}^{(2)} \end{bmatrix}, \quad M_2 = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & -\mu_{32} & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & -\mu_{m2} & 0 & \dots & 1 \end{bmatrix}, \quad b^{(2)} = \begin{bmatrix} b_1 \\ b_2^{(1)} \\ b_3^{(2)} \\ \vdots \\ b_m^{(2)} \end{bmatrix}.$$

После  $(m-1)$ -го шага, завершающего прямой ход, система оказывается приведенной к виду

$$A^{(m-1)} x = b^{(m-1)} \tag{5.53}$$

с верхней треугольной матрицей  $A^{(m-1)}$ . Здесь

$$A^{(m-1)} = M_{m-1} A^{(m-2)}, \quad b^{(m-1)} = M_{m-1} b^{(m-2)},$$

$$A^{(m-1)} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1m} \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} & \dots & a_{2m}^{(1)} \\ 0 & 0 & a_{33}^{(2)} & \dots & a_{3m}^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & a_{mm}^{(m-1)} \end{bmatrix}, \quad M_{m-1} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 & 0 \\ 0 & 1 & 0 & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 1 & 0 \\ 0 & 0 & 0 & \dots & -\mu_{m,m-1} & 1 \end{bmatrix},$$

$$b^{(m-1)} = \begin{bmatrix} b_1 \\ b_2^{(1)} \\ b_3^{(2)} \\ \vdots \\ b_m^{(m-1)} \end{bmatrix}.$$

Заметим, что матрица  $A^{(m-1)}$  получена из матрицы  $A$  последовательным умножением на  $M_1, M_2, \dots, M_{m-1}$ :

$$A^{(m-1)} = M_{m-1} \dots M_2 M_1 A. \quad (5.54)$$

Аналогично,

$$b^{(m-1)} = M_{m-1} \dots M_2 M_1 b. \quad (5.55)$$

Из равенства (5.54) вытекает следующее представление:

$$A = M_1^{-1} M_2^{-1} \dots M_{m-1}^{-1} A^{(m-1)}. \quad (5.56)$$

Как легко проверить,

$$M_1^{-1} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ \mu_{21} & 1 & 0 & \dots & 0 \\ \mu_{31} & 0 & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ \mu_{m1} & 0 & 0 & \dots & 1 \end{bmatrix}, \quad M_2^{-1} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & \mu_{32} & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & \mu_{m2} & 0 & \dots & 1 \end{bmatrix}, \dots,$$

$$M_{m-1}^{-1} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 & 0 \\ 0 & 1 & 0 & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 1 & 0 \\ 0 & 0 & 0 & \dots & \mu_{m,m-1} & 1 \end{bmatrix}.$$

Для этого достаточно перемножить матрицы  $M_k^{-1}$  и  $M_k$  ( $k = 1, \dots, m-1$ ), в результате чего получится единичная матрица.

Введем обозначения  $U = A^{(m-1)}$ ,  $L = M_1^{-1} M_2^{-1} \dots M_{m-1}^{-1}$ . Вычисляя матрицу  $L$ , убеждаемся в том, что она имеет следующий вид:

$$L = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ \mu_{21} & 1 & 0 & \dots & 0 \\ \mu_{31} & \mu_{32} & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ \mu_{m1} & \mu_{m2} & \mu_{m3} & \dots & 1 \end{bmatrix}. \quad (5.57)$$

Тогда равенство (5.56) в новых обозначениях примет вид

$$A = LU. \quad (5.58)$$

Это и есть<sup>1</sup>  $LU$ -разложение матрицы  $A$  — представление матрицы  $A$  в виде произведения нижней треугольной матрицы  $L$  и верхней треугольной матрицы  $U$ .

Таким образом, прямой ход метода Гаусса без перестановок можно рассматривать как процесс вычисления  $LU$ -разложения матрицы системы, на  $k$ -м шаге которого определяются элементы  $k$ -го столбца матрицы  $L$  и  $k$ -й строки матрицы  $U$ .

Возможность  $LU$ -разложения обосновывается следующей теоремой.

**Теорема 5.3.** Если все главные миноры матрицы  $A$  отличны от нуля, то существуют единственные нижняя треугольная матрица  $L$  вида (5.57) и верхняя треугольная матрица  $U$  такие, что  $A = LU$ .

Структура матриц  $L$  и  $U$  позволяет организовывать компактное размещение элементов этих матриц в памяти ЭВМ по мере их вычисления. На  $k$ -м шаге исключения в области памяти, где первоначально располагалась матрица  $A$ , размещается матрица

$$\begin{bmatrix} a_{11} & a_{12} & \dots & a_{1k} & a_{1,k+1} & \dots & a_{1m} \\ \mu_{21} & a_{22}^{(1)} & \dots & a_{2k}^{(1)} & a_{2,k+1}^{(1)} & \dots & a_{2m}^{(1)} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \mu_{k1} & \mu_{k2} & \dots & a_{kk}^{(k-1)} & a_{k,k+1}^{(k-1)} & \dots & a_{km}^{(k-1)} \\ \mu_{k+1,1} & \mu_{k+1,2} & \dots & \mu_{k+1,k} & a_{k+1,k+1}^{(k)} & \dots & a_{k+1,m}^{(k)} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \mu_{m1} & \mu_{m2} & \dots & \mu_{mk} & a_{m,k+1}^{(k)} & \dots & a_{mm}^{(k)} \end{bmatrix}.$$

<sup>1</sup> Обозначения треугольных матриц буквами  $L$  и  $U$  вызваны тем, что эти буквы являются начальными в английских словах lower — "нижний" и upper — "верхний".

При этом вся необходимая для дальнейших вычислений информация сохраняется.

**Пример 5.12.** Проиллюстрируем  $LU$ -разложение на примере решения системы (5.35). На основании данных табл. 5.2 можно записать

$$L = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0.5 & 1 & 0 & 0 \\ 0.3 & -1.6 & 1 & 0 \\ 0 & -3 & 2.5 & 1 \end{bmatrix}, \quad U = \begin{bmatrix} 10 & 6 & 2 & 0 \\ 0 & -2 & -3 & 4 \\ 0 & 0 & -4.4 & 5.4 \\ 0 & 0 & 0 & 0.5 \end{bmatrix}.$$

Следовательно,  $LU$ -разложение матрицы системы имеет вид

$$\begin{bmatrix} 10 & 6 & 2 & 0 \\ 5 & 1 & -2 & 4 \\ 3 & 5 & 1 & -1 \\ 0 & 6 & -2 & 2 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0.5 & 1 & 0 & 0 \\ 0.3 & -1.6 & 1 & 0 \\ 0 & -3 & 2.5 & 1 \end{bmatrix} \cdot \begin{bmatrix} 10 & 6 & 2 & 0 \\ 0 & -2 & -3 & 4 \\ 0 & 0 & -4.4 & 5.4 \\ 0 & 0 & 0 & 0.5 \end{bmatrix}.$$

**2. Использование  $LU$ -разложения.** В современных программах, реализующих метод Гаусса на ЭВМ, вычисления разбивают на два основных этапа. Первый этап — это вычисление  $LU$ -разложения матрицы системы. Второй этап — обработка правых частей и вычисление решения.

Смысл выделения первого этапа состоит в том, что он может быть выполнен независимо, для его проведения не нужна информация о правой части системы. Это как бы этап предварительной подготовки к быстрому вычислению решения. Именно для получения  $LU$ -разложения производится основная масса вычислений (примерно  $(2/3)m^3$  арифметических операций).

На втором этапе выполняют следующие действия:

1<sup>0</sup>. Преобразуют правую часть  $\mathbf{b}$  по формулам прямого хода; необходимые для вычисления коэффициенты  $\mu_{ij}$  берут из матрицы  $L$ . В результате получают вектор  $\mathbf{b}^{(m-1)}$ , связанный с вектором  $\mathbf{b}$  формулой (5.55).

2<sup>0</sup>. С помощью обратной подстановки решают систему  $U\mathbf{x} = \mathbf{b}^{(m-1)}$ .

Для непосредственного вычисления решения  $\mathbf{x}$  на втором этапе требуется примерно  $2m^2$  арифметических операций.

В случае, если необходимо решить  $p$  систем уравнений с фиксированной матрицей  $A$  и различными правыми частями  $\mathbf{d}_{(1)}, \mathbf{d}_{(2)}, \dots, \mathbf{d}_{(p)}$ , первый этап проводят лишь один раз. Затем последовательно  $p$  раз проводят вычисления второго этапа для получения решений  $\mathbf{x}_{(1)}, \mathbf{x}_{(2)}, \dots, \mathbf{x}_{(p)}$ . Для этого, как и в § 5.6, требуется примерно  $(2/3)m^3 + 2pm^2$  арифметических операций.



**Пример 5.13.** Решим систему

$$\begin{aligned} 10x_1 + 6x_2 + 2x_3 &= 8, \\ 5x_1 + x_2 - 2x_3 + 4x_4 &= 7, \\ 3x_1 + 5x_2 + x_3 - x_4 &= 2, \\ 6x_2 - 2x_3 + 2x_4 &= 2. \end{aligned}$$

Воспользуемся  $LU$ -разложением матрицы системы, указанным в примере 5.12. Сначала преобразуем вектор правой части  $\mathbf{b} = (8, 7, 2, 2)^T$  по формулам прямого хода.

1-й шаг.  $b_2^{(1)} = b_2 - \mu_{21}b_1 = 7 - 0.5 \cdot 8 = 3$ ,  $b_3^{(1)} = b_3 - \mu_{31}b_1 = 2 - 0.3 \cdot 8 = -0.4$ ,  $b_4^{(1)} = b_4 - \mu_{41}b_1 = 2 - 0 \cdot 8 = 2$ . После 1-го шага получим  $\mathbf{b}^{(1)} = (8, 3, -0.4, 2)^T$ .

2-й шаг.  $b_3^{(2)} = b_3^{(1)} - \mu_{32}b_2^{(1)} = -0.4 - (-1.6) \cdot 3 = 4.4$ ,  $b_4^{(2)} = b_4^{(1)} - \mu_{42}b_2^{(1)} = 2 - (-3) \cdot 3 = 11$ . После 2-го шага найдем  $\mathbf{b}^{(2)} = (8, 3, 4.4, 11)^T$ .

3-й шаг.  $b_4^{(3)} = b_4^{(2)} - \mu_{43}b_3^{(2)} = 11 - 2.5 \cdot 4.4 = 0$ . В результате прямого хода получен вектор  $\mathbf{b}^{(3)} = (8, 3, 4.4, 0)^T$  и система приведена к виду

$$\begin{aligned} 10x_1 + 6x_2 + 2x_3 &= 8, \\ -2x_2 - 3x_3 + 4x_4 &= 3, \\ -4.4x_3 + 5.4x_4 &= 4.4, \\ 0.5x_4 &= 0. \end{aligned}$$

Обратный ход дает значения неизвестных  $x_4 = 0$ ,  $x_3 = -1$ ,  $x_2 = 0$ ,  $x_1 = 1$ .

**3. Метод Гаусса с выбором главного элемента и разложение матрицы на множители.** В отличие от схемы единственного деления схема частичного выбора предполагает на  $k$ -м шаге прямого хода перестановку уравнений системы с номерами  $i_k$  и  $k$  (при выборе в качестве главного элемента  $k$ -го шага элемента  $a_{i_k k}$ ). Это преобразование эквивалентно умножению системы на матрицу  $P_k$ , которая получается из единичной матрицы перестановкой  $i_k$ -й и  $k$ -й строк (см. пример 5.14). Исключение неизвестного на  $k$ -м шаге по-прежнему эквивалентно умножению системы на матрицу  $M_k$ .

Таким образом, после 1-го шага система  $A\mathbf{x} = \mathbf{b}$  преобразуется к виду  $A^{(1)}\mathbf{x} = \mathbf{b}^{(1)}$ , где  $A^{(1)} = M_1 P_1 A$ ,  $\mathbf{b}^{(1)} = M_1 P_1 \mathbf{b}$ . После 2-го шага система преобразуется к виду  $A^{(2)}\mathbf{x} = \mathbf{b}^{(2)}$ , где  $A^{(2)} = M_2 P_2 A^{(1)}$ ,  $\mathbf{b}^{(2)} = M_2 P_2 \mathbf{b}^{(1)}$ .

После завершающего  $(m-1)$ -го шага прямого хода система оказывается приведенной к виду  $A^{(m-1)}\mathbf{x} = \mathbf{b}^{(m-1)}$ , где  $A^{(m-1)} = M_{m-1} P_{m-1} A^{(m-2)}$ ,  $\mathbf{b}^{(m-1)} = M_{m-1} P_{m-1} \mathbf{b}^{(m-2)}$ .

Как нетрудно видеть,

$$A^{(m-1)} = M_{m-1}P_{m-1} \dots M_2P_2M_1P_1A, \quad (5.59)$$

$$b^{(m-1)} = M_{m-1}P_{m-1} \dots M_2P_2M_1P_1b. \quad (5.60)$$

Равенство (5.59) равносильно следующему разложению матрицы  $A$  на множители:

$$A = P_1^{-1}M_1^{-1}P_2^{-1}M_2^{-1} \dots P_{m-1}^{-1}M_{m-1}^{-1}U, \quad (5.61)$$

где  $U = A^{(m-1)}$  — верхняя треугольная матрица.

Разложение (5.61) не является  $LU$ -разложением матрицы  $A$ . Однако прямой ход по-прежнему равносильен  $LU$ -разложению, но уже не самой матрицы  $A$ , а матрицы  $\tilde{A}$ , полученной из нее в результате соответствующей перестановки строк. Это разложение имеет вид

$$\tilde{A} = \tilde{L}U, \quad (5.62)$$

где  $\tilde{A} = P_{m-1}P_{m-2} \dots P_2P_1A$ ,  $\tilde{L}$  — нижняя треугольная матрица, отличающаяся от матрицы (5.57) перестановкой множителей в столбцах.

**Пример 5.14.** Найдем разложение вида (5.62) для матрицы системы (5.39), используя результаты вычислений примера 5.9. Так как 1-й шаг прямого хода не потребовал перестановки, а на 2-м шаге были переставлены второе и третье уравнения, то

$$P_1 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad P_2 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix}, \quad \tilde{A} = \begin{bmatrix} 2 & -9 & 5 \\ 1 & -1 & -7.5 \\ 1.2 & -5.3999 & 6 \end{bmatrix}.$$

Для матрицы  $\tilde{A}$  прямой ход уже проводится по схеме единственного деления. Отличие от вычислений примера 5.9 состоит в том, что на 2-м шаге множители  $\mu_{21}$  и  $\mu_{31}$ , а также второе и третье уравнения системы (5.40) меняются местами. В результате получим разложение вида (5.62), где

$$\tilde{L} = \begin{bmatrix} 1 & 0 & 0 \\ 0.5 & 1 & 0 \\ 0.6 & 2.9 \cdot 10^{-5} & 1 \end{bmatrix}, \quad U = \begin{bmatrix} 2 & -9 & 5 \\ 0 & 3.5 & -10 \\ 0 & 0 & 3.00029 \end{bmatrix}.$$

После получения разложения вида (5.62) для решения системы  $Ax = b$  выполняют следующие действия.

1°. Правую часть перестановкой элементов приводят к виду  $\tilde{b} = P_{m-1}P_{m-2} \dots P_2P_1b$ .

2°. Преобразуют вектор  $\tilde{b}$  по формулам прямого хода; необходимые для вычислений множители  $\tilde{\mu}_{ij}$  берут из матрицы  $\tilde{L}$ . В результате получают вектор  $b^{(m-1)}$ .

3°. Обратной подстановкой решают систему  $Ux = b^{(m-1)}$ .

Заметим, что матрица перестановки  $P_k$  полностью определяется заданием номера  $i_k$  уравнения, которое переставляется с  $k$ -м уравнением. Поэтому для хранения всей информации о перестановках достаточно целочисленного массива длины  $m - 1$ .

**Пример 5.15.** Решим систему (5.39), используя полученное в примере 5.14 разложение матрицы  $\tilde{A}$ .

Здесь вектор  $\mathbf{b} = (-4, 0.6001, -8.5)^T$  преобразуется в вектор  $\tilde{\mathbf{b}} = (-4, -8.5, 0.6001)^T$  перестановкой второго и третьего элементов.

**Прямой ход.** 1-й шаг.  $b_2^{(1)} = \tilde{b}_2 - \tilde{\mu}_{21}\tilde{b}_1 = -8.5 - 0.5(-4) = -6.5$ ,  
 $b_3^{(1)} = \tilde{b}_3 - \tilde{\mu}_{31}\tilde{b}_1 = 0.6001 - 0.6 \cdot (-4) = 3.0001$ . В результате 1-го шага имеем  
 $\mathbf{b}^{(1)} = (-4, -6.5, 3.0001)^T$ .

2-й шаг.  $b_3^{(2)} = b_3^{(1)} - \tilde{\mu}_{32}b_2^{(1)} = 3.0001 - 2.9 \cdot 10^{-5} \cdot (-6.5) \approx 3.00029$ . В результате прямого хода правая часть оказалась приведенной к виду  $\mathbf{b}^{(2)} = (-4, -6.5, 3.00029)^T$ .

**Обратный ход** проводится точно так же, как в примере 5.9, и дает значения  $x_3 = 1$ ,  $x_2 = 1$ ,  $x_1 = 0$ .

## § 5.8. Метод Холецкого (метод квадратных корней)

**1. Описание метода.** Пусть требуется решить систему линейных алгебраических уравнений

$$A\mathbf{x} = \mathbf{b} \quad (5.63)$$

с симметричной положительно определенной матрицей  $A$ . Линейные системы такого типа часто встречаются в приложениях (например, в задачах оптимизации, при решении уравнений математической физики и др.). Для их решения весьма часто применяется *метод Холецкого* (другое название — *метод квадратных корней*).

В основе метода лежит алгоритм построения специального  $LU$ -разложения матрицы  $A$ , в результате чего она приводится к виду

$$A = LL^T. \quad (5.64)$$

В разложении (5.64) нижняя треугольная матрица

$$L = \begin{bmatrix} l_{11} & 0 & \dots & 0 \\ l_{21} & l_{22} & \dots & 0 \\ \dots & \dots & \dots & \dots \\ l_{m1} & l_{m2} & \dots & l_{mm} \end{bmatrix} \quad (5.65)$$

уже не обязательно должна иметь на главной диагонали единицы, как это было в методе Гаусса, а требуется только, чтобы диагональные элементы  $l_{ii}$  были положительными.

Если разложение (5.64) получено, то решение системы (5.63) сводится к последовательному решению двух систем с треугольными матрицами:

$$Ly = b, \quad L^T x = y. \quad (5.66)$$

Для решения систем (5.66) требуется выполнение примерно  $2m^2$  арифметических операций.

Найдем элементы матрицы  $L$ . Для этого вычислим элементы матрицы  $LL^T$  и приравняем их соответствующим элементам матрицы  $A$ . В результате получим систему уравнений

$$\begin{aligned} l_{11}^2 &= a_{11}, \\ l_{i1}l_{11} &= a_{i1}, \quad i = 2, 3, \dots, m, \\ l_{21}^2 + l_{22}^2 &= a_{22}, \\ l_{i1}l_{21} + l_{i2}l_{22} &= a_{i2}, \quad i = 3, 4, \dots, m, \\ &\dots \dots \dots \\ l_{k1}^2 + l_{k2}^2 + \dots + l_{kk}^2 &= a_{kk}, \\ l_{i1}l_{k1} + l_{i2}l_{k2} + \dots + l_{ik}l_{kk} &= a_{ik}, \quad i = k+1, \dots, m, \\ &\dots \dots \dots \\ l_{m1}^2 + l_{m2}^2 + \dots + l_{mm}^2 &= a_{mm}. \end{aligned} \quad (5.67)$$

Решая систему (5.67), последовательно находим

$$\begin{aligned} l_{11} &= \sqrt{a_{11}}, \\ l_{i1} &= a_{i1}/l_{11}, \quad i = 2, 3, \dots, m, \\ l_{22} &= \sqrt{a_{22} - l_{21}^2}, \\ l_{i2} &= (a_{i2} - l_{i1}l_{21})/l_{22}, \quad i = 3, 4, \dots, m, \\ &\dots \dots \dots \\ l_{kk} &= \sqrt{a_{kk} - l_{k1}^2 - l_{k2}^2 - \dots - l_{k,k-1}^2}, \\ l_{ik} &= (a_{ik} - l_{i1}l_{k1} - l_{i2}l_{k2} - \dots - l_{i,k-1}l_{k,k-1})/l_{kk}, \quad i = k+1, \dots, m, \\ &\dots \dots \dots \\ l_{mm} &= \sqrt{a_{mm} - l_{m1}^2 - l_{m2}^2 - \dots - l_{m,m-1}^2}. \end{aligned} \quad (5.68)$$

Заметим, что для вычисления диагональных элементов используется операция извлечения квадратного корня. Поэтому метод Холецкого

называют еще и методом квадратных корней. Доказано, что положительность соответствующих подкоренных выражений является следствием положительной определенности матрицы  $A$ .

**2. Достоинства метода.** Метод Холецкого обладает рядом ценных качеств, которые позволяют предпочесть его методу Гаусса, если требуется решить систему линейных алгебраических уравнений с симметричной и положительно определенной матрицей.

Как нетрудно подсчитать, число операций, выполняемых в ходе вычисления разложения (5.64) по формулам (5.68), равно примерно  $m^3/3$ . Учитывая, что для решения систем (5.66) требуется примерно  $2m^2$  арифметических операций, убеждаемся, что при больших  $m$  метод Холецкого требует вдвое меньше вычислительных затрат по сравнению с методом Гаусса.

Учет симметричности матрицы  $A$  позволяет экономно использовать память ЭВМ при записи исходных данных задачи и результатов вычислений. Действительно, для задания матрицы  $A$  достаточно ввести в память ЭВМ только элементы  $a_{ij}$  ( $i \geq j$ ), расположенные на главной диагонали и под ней. В формулах (5.68) каждый такой элемент  $a_{ij}$  используется лишь однажды для получения  $l_{ij}$  и далее в вычислениях не участвует. Поэтому в процессе вычислений найденные элементы  $l_{ij}$  могут последовательно замещать элементы  $a_{ij}$ .

В результате нижняя треугольная матрица  $L$  может быть расположена в той области памяти, где первоначально хранилась нижняя треугольная часть матрицы  $A$ . Применение для решения системы (5.63) метода Гаусса потребовало бы использования примерно вдвое большего объема памяти.

Безусловным достоинством метода Холецкого является также его гарантированная устойчивость.

**Пример 5.16.** Используя метод Холецкого, найдем решение системы уравнений с симметричной положительно определенной матрицей:

$$\begin{aligned} 6.25x_1 - x_2 + 0.5x_3 &= 7.5, \\ -x_1 + 5x_2 + 2.12x_3 &= -8.68, \\ 0.5x_1 + 2.12x_2 + 3.6x_3 &= -0.24. \end{aligned}$$

По формулам (5.68) последовательно находим

$$\begin{aligned} l_{11} &= \sqrt{a_{11}} = \sqrt{6.25} = 2.5, \quad l_{21} = a_{21}/l_{11} = -1/2.5 = -0.4, \\ l_{31} &= a_{31}/l_{11} = 0.5/2.5 = 0.2, \quad l_{22} = \sqrt{a_{22} - l_{21}^2} = \sqrt{5 - 0.16} = 2.2, \\ l_{32} &= (a_{32} - l_{31}l_{21})/(l_{22}) = (2.12 - 0.2(-0.4))/2.2 = 1, \\ l_{33} &= \sqrt{a_{33} - l_{31}^2 - l_{32}^2} = \sqrt{3.6 - 0.2^2 - 1^2} = 1.6. \end{aligned}$$

Следователно, матрица  $L$  такова:

$$L = \begin{bmatrix} 2.5 & 0 & 0 \\ -0.4 & 2.2 & 0 \\ 0.2 & 1 & 1.6 \end{bmatrix}.$$

Система  $Ly = b$  имеет вид

$$\begin{array}{rcl} 2.5y_1 & & = 7.5, \\ -0.4y_1 + 2.2y_2 & & = -8.68, \\ 0.2y_1 + & y_2 + 1.6y_3 & = -0.24. \end{array}$$

Решая ее, получаем  $y_1 = 3$ ,  $y_2 = -3.4$ ,  $y_3 = 1.6$ .

Далее из системы  $L^T x = y$ , которая имеет вид

$$\begin{array}{rcl} 2.5x_1 - 0.4x_2 + 0.2x_3 & = & 3, \\ 2.2x_2 + x_3 & = & -3.4, \\ 1.6x_3 & = & 1.6, \end{array}$$

находим решение  $x_1 = 0.8, x_2 = -2, x_3 = 1$ .

## § 5.9. Метод прогонки

Рассмотрим *метод прогонки*<sup>1</sup> — простой и эффективный алгоритм решения систем линейных алгебраических уравнений с трехдиагональными матрицами:

$$\begin{aligned} b_1 x_1 + c_1 x_2 &= d_1, \\ a_2 x_1 + b_2 x_2 + c_2 x_3 &= d_2, \\ \dots & \\ a_i x_{i-1} + b_i x_i + c_i x_{i+1} &= d_i, \\ \dots & \\ a_{m-1} x_{m-2} + b_{m-1} x_{m-1} + c_{m-1} x_m &= d_{m-1}, \\ a_m x_{m-1} + b_m x_m &= d_m. \end{aligned} \tag{5.69}$$

Системы такого вида часто возникают при решении различных задач математической физики, а также при решении других вычислительных задач (например, приближения функций сплайнами).

<sup>1</sup> Метод прогонки был предложен в начале 50-х годов независимо несколькими авторами, в том числе российскими учеными И.М. Гельфандом, О.В. Локуциевским, В.С. Владимировым, А.С. Кронродом.

**1. Вывод расчетных формул.** Преобразуем первое уравнение системы (5.69) к виду

$$x_1 = \alpha_1 x_2 + \beta_1, \quad (5.70)$$

где  $\alpha_1 = -c_1/b_1$ ,  $\beta_1 = d_1/b_1$ .

Подставим полученное для  $x_1$  выражение во второе уравнение системы:

$$a_2(\alpha_1 x_2 + \beta_1) + b_2 x_2 + c_2 x_3 = d_2.$$

Преобразуем это уравнение к виду

$$x_2 = \alpha_2 x_3 + \beta_2, \quad (5.71)$$

где  $\alpha_2 = -c_2/(b_2 + a_2\alpha_1)$ ,  $\beta_2 = (d_2 - a_2\beta_1)/(b_2 + a_2\alpha_1)$ . Выражение (5.71) подставляем в третье уравнение системы и т. д.

На  $i$ -м шаге этого процесса ( $1 < i < m$ )  $i$ -е уравнение системы преобразуется к виду

$$x_i = \alpha_i x_{i+1} + \beta_i, \quad (5.72)$$

где  $\alpha_i = -c_i/(b_i + a_i\alpha_{i-1})$ ,  $\beta_i = (d_i - a_i\beta_{i-1})/(b_i + a_i\alpha_{i-1})$ .

На  $m$ -м шаге подстановка в последнее уравнение выражения  $x_{m-1} = \alpha_{m-1}x_m + \beta_{m-1}$  дает

$$a_m(\alpha_{m-1}x_m + \beta_{m-1}) + b_mx_m = d_m.$$

Отсюда можно определить значение  $x_m$ :

$$x_m = \beta_m = (d_m - a_m\beta_{m-1})/(b_m + a_m\alpha_{m-1}).$$

Значения остальных неизвестных  $x_i$  для  $i = m-1, m-2, \dots, 1$  теперь легко вычисляются по формуле (5.72).

**2. Алгоритм прогонки.** Сделанные преобразования позволяют организовать вычисления метода прогонки в два этапа.

*Прямой ход* метода прогонки (*прямая прогонка*) состоит в вычислении прогоночных коэффициентов  $\alpha_i$  ( $1 \leq i < m$ ) и  $\beta_i$  ( $1 \leq i \leq m$ ). При  $i = 1$  коэффициенты вычисляются по формулам

$$\alpha_1 = -c_1/\gamma_1, \quad \beta_1 = d_1/\gamma_1, \quad \gamma_1 = b_1, \quad (5.73)$$

а при  $i = 2, 3, \dots, m-1$  — по рекуррентным формулам

$$\alpha_i = -c_i/\gamma_i, \quad \beta_i = (d_i - a_i\beta_{i-1})/\gamma_i, \quad \gamma_i = b_i + a_i\alpha_{i-1}. \quad (5.74)$$

При  $i = m$  прямая прогонка завершается вычислением

$$\beta_m = (d_m - a_m\beta_{m-1})/\gamma_m, \quad \gamma_m = b_m + a_m\alpha_{m-1}. \quad (5.75)$$

Обратный ход метода прогонки (*обратная прогонка*) дает значения неизвестных. Сначала полагают  $x_m = \beta_m$ . Затем значения остальных неизвестных вычисляют по формуле

$$x_i = \alpha_i x_{i+1} + \beta_i, \quad i = m-1, m-2, \dots, 1. \quad (5.76)$$

Вычисления ведут в порядке убывания значений  $i$  от  $m-1$  до 1.

**Пример 5.17.** Используя метод прогонки, решим систему

$$\begin{aligned} 5x_1 - x_2 &= 2.0, \\ 2x_1 + 4.6x_2 - x_3 &= 3.3, \\ 2x_2 + 3.6x_3 - 0.8x_4 &= 2.6, \\ 3x_3 + 4.4x_4 &= 7.2. \end{aligned}$$

**П р я м о й х о д.** Согласно формулам (5.73)–(5.75) получаем

$$\begin{aligned} \gamma_1 &= b_1 = 5, \quad \alpha_1 = -a_1/\gamma_1 = 1/5 = 0.2, \quad \beta_1 = d_1/\gamma_1 = 2.0/5 = 0.4, \\ \gamma_2 &= b_2 + a_2\alpha_1 = 4.6 + 2 \cdot 0.2 = 5, \quad \alpha_2 = -a_2/\gamma_2 = 1/5 = 0.2, \\ \beta_2 &= (d_2 - a_2\beta_1)/\gamma_2 = (3.3 - 2 \cdot 0.4)/5 = 0.5, \\ \gamma_3 &= b_3 + a_3\alpha_2 = 3.6 + 2 \cdot 0.2 = 4, \quad \alpha_3 = -a_3/\gamma_3 = 0.8/4 = 0.2, \\ \beta_3 &= (d_3 - a_3\beta_2)/\gamma_3 = (2.6 - 2 \cdot 0.5)/4 = 0.4, \\ \gamma_4 &= b_4 + a_4\alpha_3 = 4.4 + 3 \cdot 0.2 = 5, \\ \beta_4 &= (d_4 - a_4\beta_3)/\gamma_4 = (7.2 - 3 \cdot 0.4)/5 = 1.2. \end{aligned}$$

**О б р а т н ы й х о д.** Полагаем  $x_4 = \beta_4 = 1.2$ . Далее находим  $x_3 = \alpha_3 x_4 + \beta_3 = 0.2 \cdot 1.2 + 0.4 = 0.64$ ,  $x_2 = \alpha_2 x_3 + \beta_2 = 0.2 \cdot 0.64 + 0.5 = 0.628$ ,  $x_1 = \alpha_1 x_2 + \beta_1 = 0.2 \cdot 0.628 + 0.4 = 0.5256$ . Итак, получаем решение:  $x_1 = 0.5256$ ,  $x_2 = 0.628$ ,  $x_3 = 0.64$ ,  $x_4 = 1.2$ .

**3. Свойства метода прогонки.** Непосредственный подсчет показывает, что для реализации вычислений по формулам (5.73)–(5.76) требуется примерно  $8m$  арифметических операций, тогда как в методе Гаусса это число составляет примерно  $(2/3)m^3$ . Важно и то, что трехдиагональная структура матрицы системы позволяет использовать для ее хранения лишь  $3m - 2$  машинных слова.

Таким образом, при одной и той же производительности и оперативной памяти ЭВМ метод прогонки позволяет решать системы гораздо большей размерности, чем стандартный метод Гаусса для систем уравнений с заполненной матрицей.

Приведем простые достаточные условия на коэффициенты системы (5.69), при выполнении которых вычисления по формулам прямой прогонки могут быть доведены до конца (ни один из знаменателей  $\gamma_i$  не обратится в нуль). В частности, это гарантирует существование решения системы (5.69) и его единственность. При выполнении тех же условий коэффициенты  $\alpha_i$  при всех  $i$  удовлетворяют неравенству



$|\alpha_i| \leq 1$ , а следовательно, обратная прогонка по формуле (5.76) устойчива по входным данным (см. пример 3.27). Положим  $a_1 = 0$ ,  $b_m = 0$ .

**Теорема 5.4.** Пусть коэффициенты системы (5.69) удовлетворяют следующим условиям диагонального преобладания:

$$|b_k| \geq |a_k| + |c_k|, \quad |b_k| > |a_k| \quad (1 \leq k \leq m). \quad (5.77)$$

Тогда  $\gamma_i \neq 0$  и  $|\alpha_i| \leq 1$  для всех  $i = 1, 2, \dots, m$ .

□ Воспользуемся принципом математической индукции. Из условий теоремы имеем  $\gamma_1 = b_1 \neq 0$  и  $|\alpha_1| = |c_1|/|b_1| \leq 1$ .

Пусть теперь  $\gamma_{k-1} \neq 0$  и  $|\alpha_{k-1}| \leq 1$  для некоторого  $k > 1$ . Тогда

$$|\gamma_k| = |b_k + a_k \alpha_{k-1}| \geq |b_k| - |a_k| |\alpha_{k-1}| \geq |b_k| - |a_k|.$$

Из полученной оценки в силу условий (5.77) вытекает справедливость неравенств  $|\gamma_k| > 0$  и  $|\gamma_k| \geq |c_k|$ . Следовательно,  $\gamma_k \neq 0$  и  $|\alpha_k| = |c_k|/|\gamma_k| \leq 1$ . ■

**4. Метод прогонки и разложение матрицы на множители.** Описанный вариант метода прогонки можно рассматривать как одну из схем метода Гаусса (без выбора главного элемента), в результате прямого хода которого исходная трехдиагональная матрица

$$A = \begin{bmatrix} b_1 & c_1 & 0 & 0 & \dots & 0 & 0 & 0 \\ a_2 & b_2 & c_2 & 0 & \dots & 0 & 0 & 0 \\ 0 & a_3 & b_3 & c_3 & \dots & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \dots & a_{m-1} & b_{m-1} & c_{m-1} \\ 0 & 0 & 0 & 0 & \dots & 0 & a_m & b_m \end{bmatrix}$$

представляется в виде произведения двух двухдиагональных матриц:

$$A = LU. \quad (5.78)$$

Здесь

$$L = \begin{bmatrix} \gamma_1 & 0 & 0 & \dots & 0 & 0 \\ a_2 & \gamma_2 & 0 & \dots & 0 & 0 \\ 0 & a_3 & \gamma_3 & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & a_m & \gamma_m \end{bmatrix}, \quad U = \begin{bmatrix} 1 & -\alpha_1 & 0 & \dots & 0 & 0 \\ 0 & 1 & -\alpha_2 & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 1 & -\alpha_{m-1} \\ 0 & 0 & 0 & \dots & 0 & 1 \end{bmatrix}.$$

Так как для определения  $L$  и  $U$  нет необходимости вычислять коэффициенты  $\beta_i$ , то общее число операций на получение разложения (5.78) составляет примерно  $3m$ .

Подобно тому как это описано в § 5.7, разложение (5.78) можно использовать для решения систем с многими правыми частями. Если нужно решить  $p$  систем с матрицей  $A$ , то общее число операций составит примерно  $3m + 5mp$ .

К сожалению, при обращении матрицы  $A$  теряется ее трехдиагональная структура. Обратная матрица является заполненной, однако для ее вычисления с помощью разложения (5.78) требуется примерно  $2.5m^2$  арифметических операций.

Так как  $\det A = \det L \cdot \det U$ , а  $\det U = 1$ , то определитель трехдиагональной матрицы, после того как получено разложение (5.78), вычисляется по элементарной формуле

$$\det A = \gamma_1 \gamma_2 \dots \gamma_m.$$

**5. Некоторые варианты метода прогонки.** Наряду с изложенным выше "стандартным" вариантом метода прогонки (правой прогонкой) существует большое число других вариантов этого метода. Это методы левой прогонки, встречных прогонок, немонотонной прогонки, потоковый вариант метода прогонки. В ряде случаев эти модификации могут существенно улучшить обусловленность прогонки.

Для систем уравнений, обладающих близкой к (5.69) структурой, разработаны методы циклической прогонки, матричной прогонки и др.

С указанными вариантами метода прогонки можно подробно ознакомиться в [42], [72].

## § 5.10. $QR$ -разложение матрицы.

### Методы вращений и отражений

Метод Гаусса не является единственным методом исключения, используемым для решения систем линейных уравнений и приведения матриц к треугольному виду. Рассмотрим два метода исключения, обладающих в отличие от метода Гаусса гарантированной хорошей обусловленностью — метод вращений и метод отражений. Оба этих метода позволяют получить представление исходной матрицы  $A$  в виде произведения ортогональной<sup>1</sup> матрицы  $Q$  на верхнюю треугольную матрицу  $R$ :

---

<sup>1</sup> Напомним, что матрица  $Q$  называется ортогональной, если для нее выполнено условие  $Q^T = Q^{-1}$ , что эквивалентно равенству  $QQ^T = E$ .

$$A = QR. \quad (5.79)$$

Представление (5.79) — это *QR-разложение матрицы* на множители.

1. **Метод вращений.** Опишем прямой ход метода. На 1-м шаге неизвестное  $x_1$  исключают из всех уравнений, кроме первого. Для исключения  $x_1$  из второго уравнения вычисляют числа

$$c_{12} = \frac{a_{11}}{\sqrt{a_{11}^2 + a_{21}^2}}, \quad s_{12} = \frac{a_{21}}{\sqrt{a_{11}^2 + a_{21}^2}}, \quad (5.80)$$

**обладающие следующими свойствами:**

$$c_{12}^2 + s_{12}^2 = 1, \quad -s_{12}a_{11} + c_{12}a_{21} = 0. \quad (5.81)$$

Затем первое уравнение системы заменяют линейной комбинацией первого и второго уравнений с коэффициентами  $c_{12}$  и  $s_{12}$ , а второе уравнение — аналогичной линейной комбинацией с коэффициентами  $-s_{12}$  и  $c_{12}$ . В результате получают систему

[illegible]

**в которой**

$$\begin{aligned} a_{1j}^{(1)} &= c_{12}a_{1j} + s_{12}a_{2j}, & a_{2j}^{(1)} &= -s_{12}a_{1j} + c_{12}a_{2j}, & (1 \leq j \leq m), & (5.83) \\ b_1^{(1)} &= c_{12}b_1 + s_{12}b_2, & b_2^{(1)} &= -s_{12}b_1 + c_{12}b_2. \end{aligned}$$

Заметим, что  $a_{21}^{(1)} = -s_{12}a_{11} + c_{12}a_{21} = 0$  в силу специального выбора чисел  $c_{12}$  и  $s_{12}$  (см. равенства (5.81)).

Естественно, что в случае  $a_{21} = 0$  исходная система уже имеет вид (5.82) и в исключении неизвестного  $x_1$  из второго уравнения нет необходимости. В этом случае полагают  $c_{12} = 1$  и  $s_{12} = 0$ .

Как нетрудно видеть, преобразование исходной системы (5.1) к виду (5.82) эквивалентно умножению слева матрицы  $A$  и правой части  $b$  на матрицу  $T_{12}$ , имеющую вид

$$T_{12} = \begin{bmatrix} c_{12} & s_{12} & 0 & 0 & \dots & 0 \\ -s_{12} & c_{12} & 0 & 0 & \dots & 0 \\ 0 & 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \dots & 1 \end{bmatrix}.$$

числа

(5.84)

**системы эквивалентно умножению слева на матрицу**

$$T_{13} = \begin{bmatrix} c_{13} & 0 & s_{13} & 0 & \dots & 0 \\ 0 & 1 & 0 & 0 & \dots & 0 \\ -s_{13} & 0 & c_{13} & 0 & \dots & 0 \\ 0 & 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \dots & 1 \end{bmatrix}$$

ем уравнении обращается в нуль.

"малых" шагов) система приводится к виду

(5.85)

В матричной записи получаем

$$A^{(1)}x = b^{(1)},$$

где  $A^{(1)} = T_{1m} \dots T_{13} T_{12} A$ ,  $b^{(1)} = T_{1m} \dots T_{13} T_{12} b$ .

элементами. В ней элементы с индексами  $(k, k)$  и  $(l, l)$  равны  $c_{kl}$ , эле-

мент с индексами  $(k, l)$  равен  $s_{kl}$ , а элемент с индексами  $(l, k)$  равен  $-s_{kl}$ , причем выполнено условие

$$c_{kl}^2 + s_{kl}^2 = 1. \quad (5.86)$$

Действие матрицы  $T_{kl}$  на вектор  $x$  эквивалентно его повороту вокруг оси, перпендикулярной плоскости  $Ox_kx_l$  на угол  $\varphi_{kl}$  такой, что  $c_{kl} = \cos \varphi_{kl}$ ,  $s_{kl} = \sin \varphi_{kl}$  (существование такого угла гарантируется равенством (5.86)). Эта геометрическая интерпретация и дала название методу вращений. Операцию умножения на матрицу  $T_{kl}$  часто называют *плоским вращением* (или *преобразованием Гивенса*). Заметим, что

$T_{kl}^{-1} = T_{kl}$  и, следовательно, матрица  $T_{kl}$  ортогональная.

На 2-м шаге метода вращений, состоящем из  $m - 2$  "малых" шагов, из уравнений системы (5.85) с номерами  $i = 3, 4, \dots, m$  исключают неизвестное  $x_2$ . Для этого каждое  $i$ -ое уравнение комбинируют со вторым уравнением. В результате приходим к системе

[illegible]

В матричной форме записи получаем

$$A^{(2)}x = b^{(2)},$$

где  $A^{(2)} = T_{2m} \dots T_{24} T_{23} A^{(1)}$ ,  $b^{(2)} = T_{2m} \dots T_{24} T_{23} b^{(1)}$ .

После завершения  $(m - 1)$ -го шага система принимает вид

$$\begin{array}{rcl} a_{11}^{(m-1)} x_1 + a_{12}^{(m-1)} x_2 + a_{13}^{(m-1)} x_3 + \dots + a_{1m}^{(m-1)} x_m & = & b_1^{(m-1)}, \\ a_{22}^{(m-1)} x_2 + a_{23}^{(m-1)} x_3 + \dots + a_{2m}^{(m-1)} x_m & = & b_2^{(m-1)}, \\ a_{33}^{(m-1)} x_3 + \dots + a_{3m}^{(m-1)} x_m & = & b_3^{(m-1)}, \\ \dots & & \dots \\ a_{mm}^{(m-1)} x_m & = & b_m^{(m-1)} \end{array}$$

или в матричной форме записи

$$A^{(m-1)}x = b^{(m-1)},$$

где  $A^{(m-1)} = T_{m-1,m} A^{(m-2)}$ ,  $b^{(m-1)} = T_{m-1,m} b^{(m-2)}$ .

Введем обозначение  $R$  для полученной верхней треугольной матрицы  $A^{(m-1)}$ . Она связана с исходной матрицей  $A$  равенством

$$R = TA,$$

где  $T = T_{m-1,m} \dots T_{2m} \dots T_{23} T_{1m} \dots T_{13} T_{12}$  — матрица результирующего вращения. Заметим, что матрица  $T$  ортогональна как произведение ортогональных матриц. Обозначая  $Q = T^{-1} = T^T$ , получаем  $QR$ -разложение матрицы  $A$ .

Обратный ход метода вращений проводится точно так же, как и для метода Гаусса.

Метод вращений обладает замечательной численной устойчивостью. Для него оценка (5.43) справедлива с коэффициентом  $f(m) = 6m$ . Однако этот метод существенно более трудоемок по сравнению с методом Гаусса. Получение  $QR$ -разложения для квадратной матрицы  $A$  общего вида требует примерно  $2m^3$  арифметических операций.

**Пример 5.18.** Используя метод вращений, решим на 6-разрядной десятичной ЭВМ систему уравнений

$$\begin{aligned} 2x_1 - 9x_2 + 5x_3 &= -4, \\ 1.2x_1 - 5.3999x_2 + 6x_3 &= 0.6001, \\ x_1 - x_2 - 7.5x_3 &= -8.5. \end{aligned}$$

**Прямой ход.** 1-й шаг. Исключим  $x_1$  из второго уравнения. Для этого вычислим  $c_{12}$  и  $s_{12}$  по формулам (5.80):

$$c_{12} = \frac{2}{\sqrt{2^2 + 1.2^2}} \approx 0.857493, \quad s_{12} = \frac{1.2}{\sqrt{2^2 + 1.2^2}} \approx 0.514495.$$

Преобразуя коэффициенты первого и второго уравнений по формулам (5.83), приходим к системе

$$\begin{aligned} 2.33238x_1 - 10.4957x_2 + 7.37444x_3 &= -3.12122, \\ 7.85493 \cdot 10^{-5}x_2 + 2.57248x_3 &= 2.57256, \\ x_1 - x_2 - 7.5x_3 &= -8.5. \end{aligned}$$

Далее вычислим коэффициенты  $c_{13}$  и  $s_{13}$  по формулам (5.84):

$$c_{13} = \frac{2.33238}{\sqrt{2.33238^2 + 1^2}} \approx 0.919087, \quad s_{13} = \frac{1}{\sqrt{2.33238^2 + 1^2}} \approx 0.394055.$$

Заменяя первое и третье уравнения их линейными комбинациями с коэффициентами  $c_{13}$ ,  $s_{13}$  и  $-s_{13}$ ,  $c_{13}$  соответственно, получим систему

$$\begin{aligned} 2.53772x_1 - 10.0405x_2 + 3.82234x_3 &= -6.21814, \\ 7.85493 \cdot 10^{-5}x_2 + 2.57248x_3 &= 2.57256, \\ 3.21680x_2 - 9.79909x_3 &= -6.58231. \end{aligned}$$

2-й шаг. В полученной системе имеем  $a_{22}^{(1)} = 7.85493 \cdot 10^{-5}$ ,  $a_{32}^{(1)} = 3.21680$ . Поэтому

$$c_{23} = \frac{a_{22}^{(1)}}{\sqrt{(a_{22}^{(1)})^2 + (a_{32}^{(1)})^2}} \approx 2.44185 \cdot 10^{-5}, \quad s_{23} \approx 1.00000.$$

Заменяя второе и третье уравнения системы их линейными комбинациями с коэффициентами  $c_{23}$ ,  $s_{23}$  и  $-s_{23}$ ,  $c_{23}$  соответственно, приходим к системе

$$\begin{aligned} 2.53772x_1 - 10.0405x_2 + 3.82234x_3 &= -6.21814, \\ 3.21680x_2 - 9.79903x_3 &= -6.58225, \\ -2.57272x_3 &= -2.57272. \end{aligned}$$

Обратный ход дает последовательно значения  $x_3 = 1$ ,  $x_2 = 0.999994$ ,  $x_1 = -1.58579 \cdot 10^{-5}$ .

**2. Метод отражений.** Матрицами Хаусхолдера (или отражений) называются квадратные матрицы вида

$$V = E - 2ww^T.$$

Здесь  $w$  — вектор-столбец в  $R^m$ , имеющий единичную длину. Матрица  $V$  является ортогональной и симметричной. Умножение на нее называют преобразованиями Хаусхолдера (или отражениями). Действие матрицы  $V$  на вектор  $x$  можно интерпретировать как ортогональное отражение вектора в  $R^m$  относительно гиперплоскости, проходящей через начало координат и имеющей нормальный вектор, равный  $w$ .

Как и вращения, отражения используются для обращения в нуль элементов преобразуемой матрицы. Однако здесь с помощью одного отражения можно обратить в нуль не один элемент матрицы, а целую группу элементов некоторого столбца или строки. Поэтому, являясь почти столь же устойчивым, как и метод вращений, метод отражений позволяет получить  $QR$ -разложение квадратной матрицы общего вида примерно за  $(4/3)m^3$  арифметических операций, т.е. в полтора раза быстрее. Изложение самого метода можно найти, например, в [9].

### § 5.11. Итерационное уточнение

В большинстве случаев метод Гаусса с выбором главного элемента позволяет найти приближенное решение с довольно высокой точностью. Однако иногда возникает необходимость найти решение с большей точностью. Полезно знать, что существует метод, позволяющий найти приближенное решение с относительной точностью, сравнимой с  $\epsilon_m$ , если только число обусловленности не слишком велико. Этот метод, называемый *итерационным уточнением*, требует небольшого (примерно на 25%) увеличения машинного времени по сравнению с затратами на получение решения методом Гаусса.

Пусть  $\mathbf{x}^{(0)}$  — найденное на ЭВМ приближенное решение системы  $A\mathbf{x} = \mathbf{b}$ . Напомним (см. § 5.1), что невязка  $\mathbf{r}^{(0)} = \mathbf{b} - A\mathbf{x}^{(0)}$  и погрешность  $\mathbf{e}^{(0)} = \mathbf{x} - \mathbf{x}^{(0)}$  связаны равенством

$$A\mathbf{e}^{(0)} = \mathbf{r}^{(0)}. \quad (5.87)$$

Если бы удалось найти  $\mathbf{e}^{(0)}$  как точное решение системы (5.87), то вектор  $\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \mathbf{e}^{(0)}$  дал бы точное решение системы  $A\mathbf{x} = \mathbf{b}$ . Однако в действительности вычисленное на ЭВМ значение  $\mathbf{x}^{(1)}$  неизбежно будет содержать ошибку. Тем не менее можно ожидать, что  $\mathbf{x}^{(1)}$  окажется лучшим приближением, чем  $\mathbf{x}^{(0)}$ . Используя приближение  $\mathbf{x}^{(1)}$ , аналогичным образом можно найти приближение  $\mathbf{x}^{(2)}$ .

Опишем более подробно очередной  $(k+1)$ -й шаг метода.

1°. Вычисляют  $\mathbf{r}^{(k)} \approx \mathbf{b} - A\mathbf{x}^{(k)}$ . Исключительно важно, чтобы вычисление  $\mathbf{r}^{(k)}$  производилось с повышенной точностью. Дело в том, что  $\mathbf{b} \approx A\mathbf{x}^{(k)}$  и поэтому при вычислении невязки неизбежно вычитание близких чисел, а следовательно, потеря большого числа значащих цифр. Одна из возможностей состоит в использовании для вычисления  $A\mathbf{x}^{(k)}$  и  $\mathbf{b} - A\mathbf{x}^{(k)}$  арифметики удвоенной точности.

2°. Вычисляют решение системы  $A\mathbf{e}^{(k)} = \mathbf{r}^{(k)}$ . Так как матрица  $A$  не меняется, то получение очередного приближения с использованием однажды вычисленного  $LU$ -разложения матрицы  $A$  (с учетом необходимых перестановок строк) требует сравнительно небольшого числа (примерно  $m^2$ ) арифметических действий.

3°. Вычисляют  $\mathbf{x}^{(k+1)} \approx \mathbf{x}^{(k)} + \mathbf{e}^{(k)}$ .

Если число обусловленности не очень велико (например,  $\text{cond}(A) \ll \epsilon_m^{-1}$ ), то метод довольно быстро сходится. Сходимость характеризуется постепенным установлением значащих цифр в приближениях  $\mathbf{x}^{(k)}$ . Если же процесс расходится, то в приближениях не устанавливаются даже старшие значащие цифры.

Необходимо отметить одну интересную особенность. В процессе



итерационного уточнения невязки  $r^{(k)}$  обычно не уменьшаются, а даже несколько возрастают по величине.

Кроме того, как оказывается, приближения  $x^{(k)}$  могут быть использованы для грубого по порядку оценивания естественного числа обусловленности  $\nu_\delta(x)$ . Для этого достаточно воспользоваться приближенной формулой

$$\nu_\delta(x) \approx \varepsilon_M^{-1} \|e^{(k)}\| / \|x^{(k)}\|. \quad (5.88)$$

**Пример 5.19.** Используя алгоритм итерационного уточнения, найдем решение системы

$$\begin{aligned} 1.03x_1 + 0.991x_2 &= 2.51, \\ 0.991x_1 + 0.943x_2 &= 2.41 \end{aligned} \quad (5.89)$$

на 3-разрядной десятичной ЭВМ, считая, что режим вычислений с удвоенной точностью на ней эквивалентен использованию 6-разрядной десятичной ЭВМ.

Вычислим множитель первого (и в данном случае последнего) шага прямого хода метода Гаусса:  $\mu = 0.991/1.03 \approx 0.962$ . Так как при вычислении на 3-разрядной ЭВМ имеем  $0.943 - 0.991 \cdot 0.962 \approx -0.01$  и  $2.41 - 2.51 \cdot 0.962 \approx 0$ , то второе уравнение системы (5.89) приводится к виду  $-0.01x_2 = 0$ .

Обратная подстановка дает, приближенное решение  $x_1^{(0)} = 2.44$ ,  $x_2^{(0)} = 0$ .

**И т е р а ц и о н н о е у т о ч н е н и е. 1-й шаг.** Вычислим (с удвоенной точностью) компоненты невязки:

$$r_1^{(0)} = 2.51 - 1.03x_1^{(0)} - 0.991x_2^{(0)} = -0.00320,$$

$$r_2^{(0)} = 2.41 - 0.991x_1^{(0)} - 0.943x_2^{(0)} = -0.00840$$

Вычисляя методом Гаусса решение системы

$$1.03e_1^{(0)} + 0.991e_2^{(0)} = -0.00320,$$

$$0.991e_1^{(0)} + 0.943e_2^{(0)} = -0.00840,$$

получим  $e_1^{(0)} = -0.481$ ,  $e_2^{(0)} = 0.496$ . Завершается 1-й шаг вычислением  $x_1 = x_1^{(0)} + e_1^{(0)}$ ,  $x_2 = x_2^{(0)} + e_2^{(0)}$ , приводящим на 3-разрядной ЭВМ к значениям  $x_1^{(1)} = 1.96$ ,  $x_2^{(1)} = 0.496$ .

2-й шаг дает значения  $r_1^{(1)} = -0.000336$ ,  $r_2^{(1)} = -0.000088$ ,  $e_1^{(1)} = 0.0223$ ,  $e_2^{(1)} = -0.0235$  и  $x_1^{(2)} = 1.98$ ,  $x_2^{(2)} = 0.473$ .

3-й шаг дает значения  $r_1^{(2)} = 0.00186$ ,  $r_2^{(2)} = 0.00178$ ,  $e_1^{(2)} = 0.00084$ ,  $e_2^{(2)} = 0.001$  и  $x_1^{(3)} = 1.98$ ,  $x_2^{(3)} = 0.474$ .

Сравнивая  $x^{(2)}$  и  $x^{(3)}$ , замечаем, что последние значащие цифры практи-

чески установились и, следовательно, процесс следует завершить, приняв  $x_1 \approx 1.98$ ,  $x_2 \approx 0.474$ .

Использование формулы (5.88) с  $\varepsilon_M = 5 \cdot 10^{-4}$  дает следующую оценку естественного числа обусловленности:

$$\nu_\delta(x) \approx \varepsilon_M^{-1} \|e^{(0)}\|_\infty / \|x^{(0)}\|_\infty \approx 2 \cdot 10^3 \cdot 0.496 / 1.96 \approx 407.$$

Приведем для сравнения действительные значения решения и естественного числа обусловленности:  $x_1 \approx 1.9812$ ,  $x_2 \approx 0.4735$ ,  $\nu_\delta(x) \approx 273$  (см. пример 5.5).

## § 5.12. Дополнительные замечания

1. Более подробное и в то же время доступное изложение рассмотренных в этой главе вопросов можно найти, например, в [38], [39], [67], [87].

2. Предположим, что требуется решить систему  $n$  линейных алгебраических уравнений с  $m$  неизвестными, где  $m < n$ . Так как число уравнений превышает число неизвестных, то вполне вероятно, что рассматриваемая система не имеет решения. Хотя уравнения системы нельзя удовлетворить точно, можно попытаться удовлетворить их как можно точнее, минимизируя величину вектора невязки  $r = b - Ax$ . Выбор в качестве минимизируемой величины

евклидовой нормы невязки  $\|r\|_2 = \sqrt{\sum_{i=1}^n |r_i|^2}$  приводит к методу наименьших квадратов решения переопределенных систем линейных уравнений [50].

Отметим, что в гл. 11 метод наименьших квадратов рассматривается в связи с задачей приближения таблично заданной функции.

3. Интересной модификацией метода Гаусса является алгоритм Краута, основанный на изменении порядка выполнения арифметических операций. Существуют два случая, когда эта модификация может иметь преимущества. Во-первых, алгоритм Краута выгоден тогда, когда для вычислений используется микрокалькулятор, так как алгоритм позволяет избегать выписывания промежуточных результатов. Во-вторых, он приводит к меньшей вычислительной погрешности при условии, что вычисления ведутся на ЭВМ, обладающей сравнительно быстрой арифметикой с расширенной точностью или особенно быстрой операцией вычисления скалярных произведений  $(x, y) = \sum_{i=1}^m x_i y_i$ .

Обсуждение модификации Краута можно найти, например, в [67], [87].

4. Следует отметить, что в данной главе оказались практически не отраженными прямые методы решения систем уравнений с разреженными матрицами (исключение составляет § 5.9, посвященный методу прогонки). Желаящим найти доступное изложение современных прямых методов, предназначенных для решения очень больших линейных систем с разреженными матрицами, можно посоветовать обратиться к [40]. Укажем также на книги [30], [63], [94], специально посвященные технологии разреженных матриц.

## Глава 6

### ИТЕРАЦИОННЫЕ МЕТОДЫ РЕШЕНИЯ СИСТЕМ ЛИНЕЙНЫХ АЛГЕБРАИЧЕСКИХ УРАВНЕНИЙ

Системы линейных алгебраических уравнений можно решать как с помощью прямых, так и итерационных методов. Для систем уравнений средней размерности чаще используют прямые методы.

Итерационные методы применяют главным образом для решения задач большой размерности, когда использование прямых методов невозможно из-за ограничений в доступной оперативной памяти ЭВМ или из-за необходимости выполнения чрезмерно большого числа арифметических операций. Большие системы уравнений, возникающие в приложениях, как правило, являются разреженными. Методы исключения для решения систем с разреженными матрицами неудобны, например, тем, что при их использовании большое число нулевых элементов превращается в ненулевые и матрица теряет свойство разреженности. В противоположность им при использовании итерационных методов в ходе итерационного процесса матрица не меняется, и она, естественно, остается разреженной. Большая эффективность итерационных методов по сравнению с прямыми методами тесно связана с возможностью существенного использования разреженности матриц.

Применение итерационных методов для качественного решения большой системы уравнений требует серьезного использования ее структуры, специальных знаний и определенного опыта. Именно поэтому разработано большое число различных итерационных методов, каждый из которых ориентирован на решение сравнительно узкого класса задач, и существует довольно мало стандартных программ, реализующих эти методы.

В этой главе будут рассмотрены наиболее простые и известные итерационные методы, позволяющие решать достаточно широкий класс систем.

### § 6.1. Метод простой итерации

1. Приведение системы к виду, удобному для итераций. Для того чтобы применить метод простой итерации к решению системы линейных алгебраических уравнений

$$Ax = b \quad (6.1)$$

с квадратной невырожденной матрицей  $A$ , необходимо предварительно преобразовать эту систему к виду

$$\mathbf{x} = B\mathbf{x} + \mathbf{c}. \quad (6.2)$$

Здесь  $B$  — квадратная матрица с элементами  $b_{ij}$  ( $i, j = 1, 2, \dots, m$ ),  $c$  — вектор-столбец с элементами  $c_i$  ( $i = 1, 2, \dots, m$ ).

В развернутой форме записи система (6.2) имеет следующий вид:

[illegible]

Вообще говоря, операция приведения системы к виду, удобному для итераций (т.е. к виду (6.2)), не является простой и требует специальных знаний, а также существенного использования специфики системы. В некоторых случаях в таком преобразовании нет необходимости, так как сама исходная система уже имеет вид (6.2).

Самый простой способ приведения системы к виду, удобному для итераций, состоит в следующем. Из первого уравнения системы (6.1) выразим неизвестное  $x_1$ :

$$x_1 = a_{11}^{-1} (b_1 - a_{12}x_2 - a_{13}x_3 - \dots - a_{1m}x_m),$$

из второго уравнения — неизвестное  $x_2$ :

$$x_2 = a_{22}^{-1} (b_2 - a_{21}x_1 - a_{23}x_3 - \dots - a_{2m}x_m),$$

и т.д. В результате получим систему

$$\begin{aligned} x_1 &= b_{12}x_2 + b_{13}x_3 + \dots + b_{1,m-1}x_{m-1} + b_{1m}x_m + c_1, \\ x_2 &= b_{21}x_1 + b_{23}x_3 + \dots + b_{2,m-1}x_{m-1} + b_{2m}x_m + c_2, \\ x_3 &= b_{31}x_1 + b_{32}x_2 + \dots + b_{3,m-1}x_{m-1} + b_{3m}x_m + c_3, \\ &\vdots \\ x_m &= b_{m1}x_1 + b_{m2}x_2 + b_{m3}x_3 + \dots + b_{m,m-1}x_{m-1} + c_m, \end{aligned} \quad (6.4)$$

в которой на главной диагонали матрицы  $B$  находятся нулевые элементы. Остальные элементы выражаются по формулам

$$b_{ij} = -a_{ij}/a_{ii}, \quad c_i = b_i/a_{ii} \quad (i, j = 1, 2, \dots, m, j \neq i). \quad (6.5)$$

Конечно, для возможности выполнения указанного преобразования необходимо, чтобы диагональные элементы матрицы  $A$  были ненулевыми.

Часто систему (6.1) преобразуют к виду  $\mathbf{x} = \mathbf{x} - \tau(\mathbf{Ax} - \mathbf{b})$ , где  $\tau$  — специально выбираемый числовой параметр (см. п. 5).

2. **Описание метода.** Выберем начальное приближение  $\mathbf{x}^{(0)} = (x_1^{(0)}, x_2^{(0)}, \dots, x_m^{(0)})^T$ . Подставляя его в правую часть системы (6.2) и вычисляя полученное выражение, находим первое приближение

$$\mathbf{x}^{(1)} = B\mathbf{x}^{(0)} + \mathbf{c}.$$

Подставляя приближение  $\mathbf{x}^{(1)}$  в правую часть системы (6.2), получим

$$\mathbf{x}^{(2)} = B\mathbf{x}^{(1)} + \mathbf{c},$$

Продолжая этот процесс далее, получим последовательность  $\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \dots, \mathbf{x}^{(n)}, \dots$  приближений, вычисляемых по формуле

$$\mathbf{x}^{(k+1)} = B\mathbf{x}^{(k)} + \mathbf{c}, k = 0, 1, 2, \dots \quad (6.6)$$

В развернутой форме записи формула (6.6) выглядит так:

$$\begin{aligned} x_1^{(k+1)} &= b_{11}x_1^{(k)} + b_{12}x_2^{(k)} + b_{13}x_3^{(k)} + \dots + b_{1m}x_m^{(k)} + c_1, \\ x_2^{(k+1)} &= b_{21}x_1^{(k)} + b_{22}x_2^{(k)} + b_{23}x_3^{(k)} + \dots + b_{2m}x_m^{(k)} + c_2, \\ &\vdots \\ x_m^{(k+1)} &= b_{m1}x_1^{(k)} + b_{m2}x_2^{(k)} + b_{m3}x_3^{(k)} + \dots + b_{mm}x_m^{(k)} + c_m. \end{aligned} \quad (6.7)$$

В случае, когда для итераций используется система (6.4) с коэффициентами, вычисленными по формулам (6.5), метод простой итерации принято называть *методом Якоби*<sup>1</sup>.

### 3. Сходимость метода простой итерации.

**Теорема 6.1.** Пусть выполнено условие

$$\|B\| < 1. \quad (6.8)$$

Тогда: 1<sup>0</sup>) решение  $\bar{x}$  системы (6.2) существует и единственно; 2<sup>0</sup>) при произвольном начальном приближении  $x^{(0)}$  метод простой итерации сходится и справедлива оценка погрешности

<sup>1</sup> Карл Густав Якоб Якоби (1804 — 1851) — немецкий математик.

$$\|x^{(n)} - \bar{x}\| \leq \|B\|^n \|x^{(0)} - \bar{x}\|. \quad (6.9)$$

10. Из курса линейной алгебры известно, что система линейных алгебраических уравнений имеет единственное решение при любой правой части тогда и только тогда, когда соответствующая однородная система имеет только нулевое решение. Пусть  $x$  — решение однородной системы  $x = Bx$ . Тогда  $\|x\| = \|Bx\| \leq \|B\| \cdot \|x\|$ . Так как по условию  $\|B\| < 1$ , это неравенство возможно только при  $\|x\| = 0$ . Следовательно,  $x = 0$  и тем самым первое утверждение теоремы доказано.

20. Вычитая из равенства (6.6) равенство  $\bar{x} = B\bar{x} + c$ , получим

$$x^{(k+1)} - \bar{x} = B(x^{(k)} - \bar{x}). \quad (6.10)$$

Вычисляя норму левой и правой частей этого равенства и используя неравенство  $\|B(x^{(k)} - \bar{x})\| \leq \|B\| \|x^{(k)} - \bar{x}\|$ , имеем  $\|x^{(k+1)} - \bar{x}\| \leq \|B\| \|x^{(k)} - \bar{x}\|$ . Так как это неравенство верно для всех  $k \geq 0$ , то

$$\begin{aligned} \|x^{(n)} - \bar{x}\| &\leq \|B\| \|x^{(n-1)} - \bar{x}\| \leq \|B\|^2 \|x^{(n-2)} - \bar{x}\| \leq \dots \leq \\ &\leq \|B\|^{n-1} \|x^{(1)} - \bar{x}\| \leq \|B\|^n \|x^{(0)} - \bar{x}\|. \end{aligned}$$

Справедливость неравенства (6.9) установлена. Учитывая, что  $\|x^{(0)} - \bar{x}\|$  не зависит от  $n$ , а  $\|B\|^n \rightarrow 0$  при  $n \rightarrow \infty$ , получаем из него, что  $\|x^{(n)} - \bar{x}\| \rightarrow 0$  при  $n \rightarrow \infty$ . ■

**З а м е ч а н и е 1.** Теорема 6.1 дает простое достаточное условие (6.8) сходимости метода простой итерации. Грубо это условие можно интерпретировать как условие достаточной малости элементов  $b_{ij}$  матрицы  $B$  в системе, приведенной к виду (6.2).

**З а м е ч а н и е 2.** Если  $\|B\| = \|B\|_\infty$ , то условие (6.8) принимает вид

$$\|B\|_\infty = \max_{1 \leq i \leq m} \sum_{j=1}^m |b_{ij}| < 1.$$

Для метода Якоби это условие в силу равенств  $b_{ii} = 0$ ,  $b_{ij} = -a_{ij}/a_{ii}$  эквивалентно условию диагонального преобладания (5.45). Если же воспользоваться условием (6.8) при  $\|B\| = \|B\|_1$ , то для метода Якоби получим другое условие диагонального преобладания:

$$\sum_{\substack{i=1 \\ i \neq j}}^m |a_{ij}| < |a_{jj}|, \quad j = 1, 2, \dots, m. \quad (6.11)$$

Таким образом, для сходимости метода Якоби достаточно, чтобы матрица  $A$  была близка к диагональной.

**З а м е ч а н и е 3.** Из оценки (6.9) следует, что при выполнении условия (6.8) метод простой итерации сходится со скоростью геометрической прогрессии, знаменатель которой  $q = \|B\|$ . Скорость сходимости тем выше, чем меньше величина  $\|B\|$ . Хотя метод сходится при любом начальном приближении  $x^{(0)}$ , из оценки (6.9) можно сделать полезный вывод: начальное приближение желательно выбирать близким к решению.

**З а м е ч а н и е 4.** Оценка погрешности (6.9) является априорной. Ее использование для формулировки критерия окончания итераций затруднительно, так как значение  $\|x^{(0)} - x\|$  неизвестно, а его грубое оценивание заведомо приведет к завышению необходимого числа итераций.

#### 4. Апостериорная оценка погрешности.

**Предложение 6.1.** Если выполнено условие (6.8), то справедлива апостериорная оценка погрешности

$$\|x^{(n)} - \bar{x}\| \leq \frac{\|B\|}{1 - \|B\|} \|x^{(n)} - x^{(n-1)}\|. \quad (6.12)$$

□ Запишем равенство (6.10) при  $k = n - 1$  в виде

$$x^{(n)} - \bar{x} = B(x^{(n-1)} - x^{(n)}) + B(x^{(n)} - \bar{x}).$$

Тогда

$$\begin{aligned} \|x^{(n)} - \bar{x}\| &= \|B(x^{(n-1)} - x^{(n)}) + B(x^{(n)} - \bar{x})\| \leq \\ &\leq \|B\| \|x^{(n-1)} - x^{(n)}\| + \|B\| \|x^{(n)} - \bar{x}\|. \end{aligned}$$

Для завершения доказательства достаточно заметить, что полученное неравенство эквивалентно неравенству (6.12). ■

**З а м е ч а н и е.** Величину, стоящую в правой части неравенства (6.12), можно легко вычислить после нахождения очередного приближения  $x^{(n)}$ .

Если требуется найти решение с точностью  $\epsilon$ , то в силу (6.12) следует вести итерации до выполнения неравенства

$$\frac{\|B\|}{1 - \|B\|} \|x^{(n)} - x^{(n-1)}\| < \epsilon.$$

Таким образом, в качестве критерия окончания итерационного процесса может быть использовано неравенство

$$\|x^{(n)} - x^{(n-1)}\| < \varepsilon_1, \quad (6.13)$$

$$\text{где } \varepsilon_1 = \frac{1 - \|B\|}{\|B\|} \varepsilon.$$

В практике вычислений иногда используют привлекательный своей простотой критерий окончания

$$\|x^{(n)} - x^{(n-1)}\| < \varepsilon. \quad (6.14)$$

Отметим, что для метода простой итерации его применение обосновано только тогда, когда  $\|B\| \leq 1/2$  (в этом случае  $(1 - \|B\|)/\|B\| \geq 1$  и выполнение неравенства (6.14) влечет за собой выполнение неравенства (6.13)). Однако в большинстве реальных случаев величина  $\|B\|$  оказывается близкой к единице и поэтому  $(1 - \|B\|)/\|B\| < 1$ . В этих случаях  $\varepsilon_1 \ll \varepsilon$  и использование критерия (6.14) приводит к существенно преждевременному окончанию итераций. Величина  $\|x^{(n)} - x^{(n-1)}\|$  здесь оказывается малой не потому, что приближения  $x^{(n-1)}$  и  $x^{(n)}$  близки к решению, а потому, что метод сходится медленно (ср. с замечанием на с. 98).

**Пример 6.1.** Используя метод простой итерации в форме Якоби, найдем решение системы

$$\begin{aligned} 6.25x_1 - x_2 + 0.5x_3 &= 7.5, \\ -x_1 + 5x_2 + 2.12x_3 &= -8.68, \\ 0.5x_1 + 2.12x_2 + 3.6x_3 &= -0.24. \end{aligned} \quad (6.15)$$

с точностью  $\varepsilon = 10^{-3}$  в норме  $\|\cdot\|_\infty$ .

Вычисляя коэффициенты по формулам (6.5), приведем систему к виду (6.4)

$$\begin{aligned} x_1 &= 0.16x_2 - 0.08x_3 + 1.2, \\ x_2 &= 0.2x_1 - 0.424x_3 - 1.736, \\ x_3 &= -0.1389x_1 - 0.5889x_2 - 0.0667. \end{aligned} \quad (6.16)$$

В последнем уравнении коэффициенты даны с точностью до погрешности округления. Здесь



$$B = \begin{bmatrix} 0 & 0.16 & -0.08 \\ 0.2 & 0 & -0.424 \\ -0.1389 & -0.5889 & 0 \end{bmatrix}, \quad c = \begin{bmatrix} 1.2 \\ -1.736 \\ -0.0667 \end{bmatrix}.$$

Достаточное условие сходимости метода простой итерации выполнено, так как  $\|B\|_{\infty} = \max \{0.24, 0.624, 0.7278\} = 0.7278 < 1$ .

Примем за начальное приближение к решению вектор  $x^{(0)} = (0, 0, 0)^T$  и будем вести итерации по формуле (6.6) до выполнения критерия окончания (6.13), где в данном случае  $\varepsilon_1 = (1 - 0.7278)/0.7278 \cdot 10^{-3} \approx 0.37 \cdot 10^{-3}$ . Значения приближений в табл. 6.1 приводятся с четырьмя цифрами после десятичной точки.

Т а б л и ц а 6.1

$n$	0	1	2	3	4
$x_1^{(n)}$	0.0000	1.2000	0.9276	0.9020	0.8449
$x_2^{(n)}$	0.0000	-1.7360	-1.4677	-1.8850	-1.8392
$x_3^{(n)}$	0.0000	-0.0667	0.7890	0.6688	0.9181
$\ x^{(n)} - x^{(n-1)}\ _{\infty}$	-	1.7360	0.8557	0.4173	0.2493

$n$	...	12	13	14	15
$x_1^{(n)}$	...	0.8006	0.8003	0.8002	0.8001
$x_2^{(n)}$	...	-1.9985	-1.9993	-1.9995	-1.9998
$x_3^{(n)}$	...	0.9987	0.9990	0.9995	0.9997
$\ x^{(n)} - x^{(n-1)}\ _{\infty}$	...	0.0018	0.0008	0.0005	0.0003

При  $n = 15$  условие (6.13) выполняется и можно положить  $x_1 = -0.800 \pm 0.001$ ,  $x_2 = -2.000 \pm 0.001$ ,  $x_3 = 1.000 \pm 0.001$ . В данном случае точные значения решения  $x_1 = -0.8$ ,  $x_2 = -2$ ,  $x_3 = 1$  нам известны (см. пример 5.16). Заметим, что в действительности решение с точностью до  $\varepsilon = 10^{-3}$  было получено уже при  $n = 13$ .

**5. Система с положительно определенной матрицей.** В случае, когда  $A$  — симметричная положительно определенная матрица, систему  $Ax = b$  часто приводят к виду

$$\mathbf{x} = \mathbf{x} - \tau(A\mathbf{x} - \mathbf{b}), \quad (6.17)$$

которому отвечает метод простой итерации:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - \tau(A\mathbf{x}^{(k)} - \mathbf{b}), \quad (6.18)$$

Здесь  $B = E - \tau A$  и параметр  $\tau > 0$  выбирают так, чтобы по возможности сделать минимальной величину  $\|B\|_2$ .

Пусть  $\lambda_{\min}$  и  $\lambda_{\max}$  — минимальное и максимальное собственные значения матрицы  $A$ . Известно, что условие  $\|B\|_2 < 1$  будет выполнено, если взять  $\tau \in (0, 2/\lambda_{\max})$ . Оптимальным является выбор  $\tau = 2/(\lambda_{\min} + \lambda_{\max})$ . В этом случае  $\|B\|_2$  принимает минимальное значение, равное  $(\lambda_{\max} - \lambda_{\min})/(\lambda_{\max} + \lambda_{\min})$ .

Чаще известны не значения  $\lambda_{\min}$  и  $\lambda_{\max}$ , а их оценки вида  $0 < \mu \leq \lambda_{\min} \leq \lambda_{\max} \leq M$  либо вида  $\lambda_{\max} \leq M$ . В первом случае полагают  $\tau = 2/(\mu + M)$ , а во втором  $\tau < 2/M$  (например,  $\tau = 1/M$ ).

Заметим, что в случае, когда  $\lambda_{\min} \ll \lambda_{\max}$  (а так бывает очень часто) при любом выборе  $\tau \in (0, 2/\lambda_{\max})$ , имеем  $\|B\|_2 \approx 1$ . Поэтому в этом случае метод (6.18) сходится очень медленно.

**6. Влияние ошибок округления.** Из-за наличия ошибок округления реально вычисляемые на ЭВМ приближения  $\tilde{\mathbf{x}}^{(n)}$  отличаются от идеальных приближений  $\mathbf{x}^{(n)}$ . Поэтому нельзя утверждать, что для любого  $\varepsilon > 0$  найдется номер  $n_0(\varepsilon)$ , начиная с которого все приближения будут находиться в  $\varepsilon$  — окрестности решения.

В действительности же существует некоторая  $\bar{\varepsilon}$  — окрестность решения, после попадания в которую приближения  $\tilde{\mathbf{x}}^{(n)}$  дальнейшего уточнения при выполнении итераций не происходит. В подтверждение сказанного приведем следующий результат.

**Теорема 6.2.** Пусть  $\|B\| < 1$ . Предположим, что вычисляемая на ЭВМ с помощью метода простых итераций последовательность  $\tilde{\mathbf{x}}^{(n)}$  удовлетворяет равенствам

$$\tilde{\mathbf{x}}^{(n+1)} = B\tilde{\mathbf{x}}^{(n)} + \mathbf{c} + \xi^{(n)}, \quad n \geq 0, \quad (6.19)$$

где  $\xi^{(n)} \in R^m$ ,  $\|\xi^{(n)}\| < \delta$ . Если вычисления по формулам (6.6) и (6.19) начинаются с одного начального приближения  $\mathbf{x}^{(0)} = \tilde{\mathbf{x}}^{(0)}$ , то для всех  $n \geq 1$  справедливы следующие оценки погрешности:

$$\|\tilde{\mathbf{x}}^{(n)} - \mathbf{x}^{(n)}\| \leq \bar{\varepsilon}, \quad (6.20)$$

$$\|\tilde{\mathbf{x}}^{(n)} - \bar{\mathbf{x}}\| \leq \|B\|^n \|\tilde{\mathbf{x}}^{(0)} - \bar{\mathbf{x}}\| + \bar{\varepsilon}, \quad (6.21)$$

$$\|\tilde{\mathbf{x}}^{(n)} - \bar{\mathbf{x}}\| \leq \frac{\|B\|}{1 - \|B\|} \|\tilde{\mathbf{x}}^{(n)} - \tilde{\mathbf{x}}^{(n-1)}\| + \bar{\varepsilon}. \quad (6.22)$$

$$\text{Здесь } \bar{\varepsilon} = \frac{\delta}{1 - |B|}.$$

Таким образом, метод простых итераций устойчив, но гарантированная точность метода ограничена величиной  $\bar{\epsilon}$ . Критерий окончания (6.13) применим, если  $\bar{\epsilon} \ll \epsilon$ .

## § 6.2. Метод Зейделя

1. **Описание метода.** Пусть система (6.1) приведена к виду (6.4) с коэффициентами, вычисленными по формулам (6.5).

Метод Зейделя<sup>1</sup> можно рассматривать как модификацию метода Якоби. Основная идея модификации состоит в том, что при вычислении очередного  $(k + 1)$ -го приближения к неизвестному  $x_i$  при  $i > 1$  используют уже найденные  $(k + 1)$ -е приближения к неизвестным  $x_1, \dots, x_{i-1}$ , а не  $k$ -е приближения, как методе Якоби.

На  $(k + 1)$ -й итерации компоненты приближения  $\mathbf{x}^{(k+1)}$  вычисляются по формулам

$$\begin{aligned} x_1^{(k+1)} &= b_{12}x_2^{(k)} + b_{13}x_3^{(k)} + \dots + b_{1m}x_m^{(k)} + c_1, \\ x_2^{(k+1)} &= b_{21}x_1^{(k+1)} + b_{23}x_3^{(k)} + \dots + b_{2m}x_m^{(k)} + c_2, \\ x_3^{(k+1)} &= b_{31}x_1^{(k+1)} + b_{32}x_2^{(k+1)} + \dots + b_{3m}x_m^{(k)} + c_3, \\ &\vdots \\ x_m^{(k+1)} &= b_{m1}x_1^{(k+1)} + b_{m2}x_2^{(k+1)} + b_{m3}x_3^{(k+1)} + \dots + c_m. \end{aligned} \quad (6.23)$$

Введем нижнюю и верхнюю треугольные матрицы

$$B_1 = \begin{bmatrix} 0 & 0 & 0 & \dots & 0 \\ b_{21} & 0 & 0 & \dots & 0 \\ b_{31} & b_{32} & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ b_{m1} & b_{m2} & b_{m3} & \dots & 0 \end{bmatrix}, B_2 = \begin{bmatrix} 0 & b_{12} & b_{13} & \dots & b_{1m} \\ 0 & 0 & b_{23} & \dots & b_{2m} \\ 0 & 0 & 0 & \dots & b_{3m} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 0 \end{bmatrix}.$$

Тогда расчетные формулы метода примут компактный вид:

<sup>1</sup> Людвиг Зейдель (1821 — 1896) — немецкий астроном и математик.

$$\mathbf{x}^{(k+1)} = B_1 \mathbf{x}^{(k+1)} + B_2 \mathbf{x}^{(k)} + \mathbf{c}. \quad (6.24)$$

Заметим, что  $B = B_1 + B_2$  и поэтому решение  $\bar{\mathbf{x}}$  исходной системы удовлетворяет равенству

$$\bar{\mathbf{x}} = B_1 \bar{\mathbf{x}} + B_2 \bar{\mathbf{x}} + \mathbf{c}. \quad (6.25)$$

Метод Зейделя иногда называют также *методом Гаусса—Зейделя*, *процессом Либмана*, *методом последовательных замещений*.

## 2. Достаточные условия сходимости.

**Теорема 6.3.** Пусть  $\|B\| < 1$ , где  $\|B\|$  — одна из норм  $\|B\|_\infty$ ,  $\|B\|_1$ . Тогда при любом выборе начального приближения  $\mathbf{x}^{(0)}$  метод Зейделя сходится со скоростью геометрической прогрессии, знаменатель которой  $q \leq \|B\|$ .

Доказательство этой теоремы опускаем. Оно довольно громоздкое, хотя и не сложное. Приведем более компактное доказательство следующей теоремы, близкое к доказательству теоремы 6.1.

**Теорема 6.4.** Пусть выполнено условие

$$\|B_1\| + \|B_2\| < 1. \quad (6.26)$$

Тогда при любом выборе начального приближения метод Зейделя сходится и верна оценка погрешности

$$\|\mathbf{x}^{(n)} - \bar{\mathbf{x}}\| \leq q^n \|\mathbf{x}^{(0)} - \bar{\mathbf{x}}\|, \quad (6.27)$$

где  $q = \|B_2\|/(1 - \|B_1\|) < 1$ .

□ Вычитая из равенства (6.24) равенство (6.25), имеем

$$\mathbf{x}^{(k+1)} - \bar{\mathbf{x}} = B_1(\mathbf{x}^{(k+1)} - \bar{\mathbf{x}}) + B_2(\mathbf{x}^{(k)} - \bar{\mathbf{x}}). \quad (6.28)$$

Вычисляя нормы левой и правой частей этого равенства и используя свойства норм, получим

$$\begin{aligned} \|\mathbf{x}^{(k+1)} - \bar{\mathbf{x}}\| &= \|B_1(\mathbf{x}^{(k+1)} - \bar{\mathbf{x}}) + B_2(\mathbf{x}^{(k)} - \bar{\mathbf{x}})\| \leq \\ &\leq \|B_1\| \|\mathbf{x}^{(k+1)} - \bar{\mathbf{x}}\| + \|B_2\| \|\mathbf{x}^{(k)} - \bar{\mathbf{x}}\|. \end{aligned}$$

Следовательно,

$$\|\mathbf{x}^{(k+1)} - \bar{\mathbf{x}}\| \leq q \|\mathbf{x}^{(k)} - \bar{\mathbf{x}}\|, \quad q = \|B_2\|/(1 - \|B_1\|).$$

Так как это неравенство верно для всех  $k \geq 0$ , то из него следует оцен-

ка (6.27). В силу условия (6.26) имеем  $0 \leq q < 1$ . Поэтому  $\mathbf{x}^{(n)} \rightarrow \bar{\mathbf{x}}$  при  $n \rightarrow \infty$ . ■

Особо выделим часто встречающийся на практике случай систем с симметричными положительно определенными матрицами.

**Теорема 6.5.** Пусть  $A$  — симметричная положительно определенная матрица. Тогда при любом выборе начального приближения  $\mathbf{x}^{(0)}$  метод Зейделя сходится со скоростью геометрической прогрессии.

Отметим, что никаких дополнительных априорных условий типа малости нормы некоторой матрицы здесь не накладывается.

### 3. Апостериорная оценка погрешности.

**Предложение 6.2.** Если выполнено условие  $\|B\| < 1$ , то для метода Зейделя справедлива апостериорная оценка погрешности

$$\|\mathbf{x}^{(n)} - \bar{\mathbf{x}}\| \leq \frac{\|B_2\|}{1 - \|B\|} \|\mathbf{x}^{(n)} - \mathbf{x}^{(n-1)}\|, \quad n \geq 1. \quad (6.29)$$

□ Положим  $k = n - 1$  и запишем равенство (6.28) в следующем виде:

$$\mathbf{x}^{(n)} - \bar{\mathbf{x}} = B(\mathbf{x}^{(n)} - \bar{\mathbf{x}}) + B_2(\mathbf{x}^{(n-1)} - \mathbf{x}^{(n)}).$$

Тогда

$$\|\mathbf{x}^{(n)} - \bar{\mathbf{x}}\| \leq \|B\| \|\mathbf{x}^{(n)} - \bar{\mathbf{x}}\| + \|B_2\| \|\mathbf{x}^{(n-1)} - \mathbf{x}^{(n)}\|,$$

откуда и следует неравенство (6.29). ■

Полученное неравенство позволяет сформулировать простой критерий окончания итерационного процесса. Если требуется найти решение с точностью  $\varepsilon > 0$ , то итерации метода Зейделя следует вести до выполнения неравенства  $\|\mathbf{x}^{(n)} - \mathbf{x}^{(n-1)}\| \|B_2\| / (1 - \|B\|) < \varepsilon$  или эквивалентного ему неравенства

$$\|\mathbf{x}^{(n)} - \mathbf{x}^{(n-1)}\| < \varepsilon_2, \quad (6.30)$$

где  $\varepsilon_2 = \frac{1 - \|B\|}{\|B_2\|} \varepsilon$ .

**4. Геометрическая интерпретация метода.** Приведем геометрическую интерпретацию метода Зейделя в случае  $m = 2$ , т.е. в случае решения системы

$$a_{11}x_1 + a_{12}x_2 = b_1,$$

$$a_{21}x_1 + a_{22}x_2 = b_2.$$

Первое уравнение задает на плоскости  $x_1 O x_2$  прямую  $l_1$ , второе — прямую  $l_2$  (рис. 6.1). Расчетные формулы метода принимают вид

$$\begin{aligned} x_1^{(k+1)} &= b_{12} x_2^{(k)} + c_1, \\ x_2^{(k+1)} &= b_{21} x_1^{(k+1)} + c_2, \end{aligned}$$

где  $b_{12} = -a_{12}/a_{11}$ ,  $c_1 = b_1/a_{11}$ ,  $b_{21} = -a_{21}/a_{22}$ ,  $c_2 = b_2/a_{22}$ .

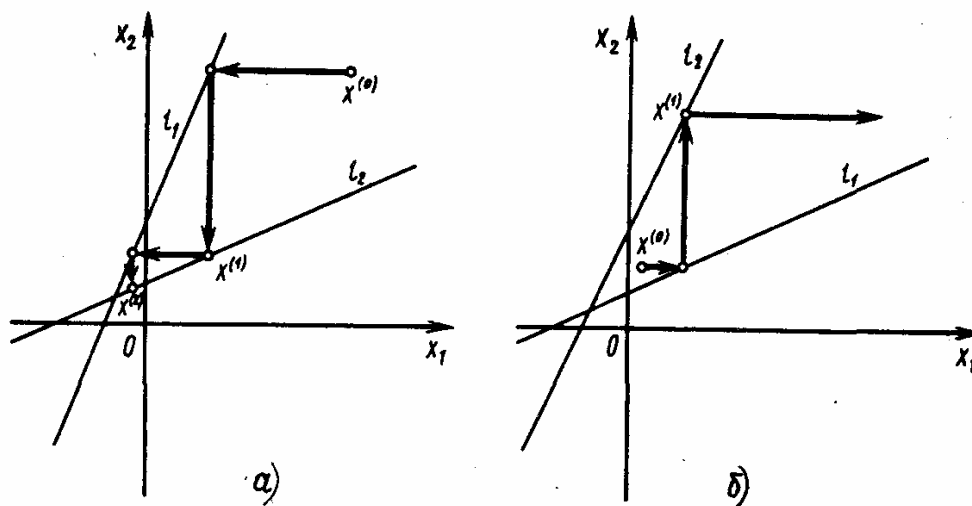


Рис. 6.1

Пусть приближение  $\mathbf{x}^{(k)}$  уже найдено. Тогда при определении  $x_1^{(k+1)}$  координата  $x_2 = x_2^{(k)}$  фиксируется и точка  $\mathbf{x}$  перемещается параллельно оси  $Ox_1$  до пересечения с прямой  $l_1$ . Координата  $x_1$  точки пересечения принимается за  $x_1^{(k+1)}$ . Затем точка  $\mathbf{x}$  перемещается вдоль прямой  $x_1 = x_1^{(k+1)}$  до пересечения с прямой  $l_2$ . Координата  $x_2$  точки пересечения принимается за  $x_2^{(k+1)}$ .

На рис. 6.1, а, б приведены геометрические иллюстрации, отвечающие сходящемуся и расходящемуся итерационному процессу Зейделя. Видно, что характер сходимости может измениться при перестановке уравнений.

**Пример 6.2.** Используя метод Зейделя, найдем решение системы (6.15) с точностью  $\epsilon = 10^{-3}$ .

После приведения системы к виду (6.16) убеждаемся, что  $\|B\|_\infty < 1$  и поэтому в силу теоремы 6.2 метод Зейделя сходится.

Положим  $\mathbf{x}^{(0)} = (0, 0, 0)^T$  и будем вычислять последовательные приближения по формулам

$$\begin{aligned}
x_1^{(k+1)} &= 0.16x_2^{(k)} - 0.08x_3^{(k)} + 1.2, \\
x_2^{(k+1)} &= 0.2x_1^{(k+1)} - 0.424x_3^{(k)} - 1.736, \\
x_3^{(k+1)} &= -0.1389x_1^{(k+1)} - 0.5889x_2^{(k+1)} - 0.0667.
\end{aligned}$$

Здесь

$$B_2 = \begin{bmatrix} 0 & 0.16 & -0.08 \\ 0 & 0 & -0.424 \\ 0 & 0 & 0 \end{bmatrix}$$

и  $\|B_2\|_\infty = 0.424$ . Будем вести итерации до выполнения критерия окончания (6.30), где  $\epsilon_2 = 10^{-3} \cdot (1 - 0.7278)/0.424 \approx 0.64 \cdot 10^{-3}$ . Значения приближений с четырьмя цифрами после десятичной точки приведены в табл. 6.2.

Т а б л и ц а 6.2

$n$	0	1	2	3	4
$x_1^{(n)}$	0.0000	1.2000	0.9088	0.8367	0.8121
$x_2^{(n)}$	0.0000	-1.4960	-1.8288	-1.9435	-1.9813
$x_3^{(n)}$	0.0000	0.6476	0.8841	0.9616	0.9873
$\ x^{(n)} - x^{(n-1)}\ _\infty$	-	1.4960	0.3328	0.1147	0.0378
$n$	5	6	7	8	
$x_1^{(n)}$	0.8040	0.8013	0.8004	0.8001	
$x_2^{(n)}$	-1.9938	-1.9980	-1.9993	-1.9998	
$x_3^{(n)}$	0.9958	0.9986	0.9995	0.9998	
$\ x^{(n)} - x^{(n-1)}\ _\infty$	0.0125	0.0041	0.0014	0.0005	

При  $n = 8$  критерий окончания выполняется и можно положить  $x_1 = 0.800 \pm 0.001$ ,  $x_2 = -2.000 \pm 0.001$ ,  $x_3 = 1.000 \pm 0.001$ . Заметим, что в действительности решение с точностью  $\epsilon = 10^{-3}$  было получено уже при  $n = 7$ .

**З а м е ч а н и е.** Существует устойчивое заблуждение, связанное с представлением о том, что метод Зейделя сходится быстрее, чем метод Якоби. Это действительно так, если матрица  $A$  симметрична и положительно определена (мы убедились в преимуществе метода Зейделя для системы уравнений с такой матрицей, решая примеры 6.1 и 6.2). Однако в общем случае возможны ситуации, когда метод Якоби сходится, а метод Зейделя сходится медленнее или вообще расходится. Возможны и противоположные ситуации. Дело в том, что эти методы ориентированы на решение разных классов систем: метод Якоби — на системы с матрицами, близкими к диагональным, а метод Зейделя — на системы с матрицами, близкими к нижним треугольным.

### § 6.3. Метод релаксации

Метод последовательной верхней релаксации является одним из наиболее эффективных и широко используемых итерационных методов для решения систем линейных алгебраических уравнений с симметричными положительно определенными матрицами  $A$ . Этот метод часто называют *SOR-методом*<sup>1</sup>. Частично популярность SOR-метода можно объяснить его простотой и тем, что он хорошо известен широкому кругу прикладников.

Суть *метода релаксации* состоит в следующем. После вычисления очередной  $i$ -й компоненты  $(k+1)$ -го приближения по формуле метода Зейделя

$$\begin{aligned} \tilde{x}_i^{(k+1)} = & b_{i1}x_1^{(k+1)} + b_{i2}x_2^{(k+1)} + \dots + b_{i,i-1}x_{i-1}^{(k+1)} + b_{i,i+1}x_{i+1}^{(k)} + \\ & + \dots + b_{im}x_m^{(k)} + c_i \end{aligned}$$

производят дополнительно смещение этой компоненты на величину  $(\omega - 1)(\tilde{x}_i^{(k+1)} - x_i^{(k)})$ , где  $\omega$  — *параметр релаксации*. Таким образом,  $i$ -я компонента  $(k+1)$ -го приближения вычисляется по формуле

$$x_i^{(k+1)} = \tilde{x}_i^{(k+1)} + (\omega - 1)(\tilde{x}_i^{(k+1)} - x_i^{(k)}) = \omega \tilde{x}_i^{(k+1)} + (1 - \omega)x_i^{(k)}.$$

На рис. 6.2 показано несколько первых итераций метода при значении параметра релаксации  $\omega = 1.25$ .

<sup>1</sup> От англ. successive over relaxation.



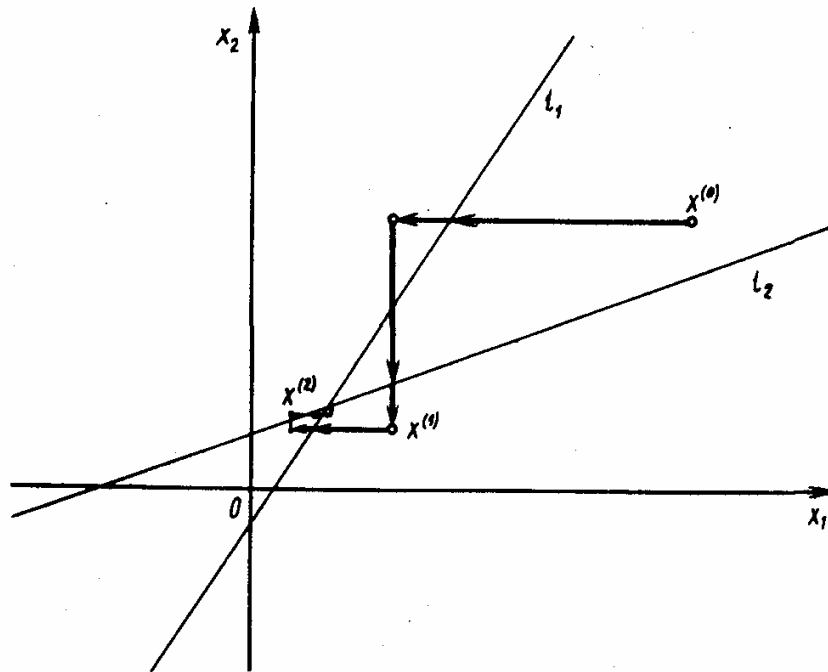


Рис. 6.2

В обозначениях предыдущего параграфа компактная формула для вычисления  $\mathbf{x}^{(k+1)}$  записывается следующим образом:

$$\mathbf{x}^{(k+1)} = (1 - \omega)\mathbf{x}^{(k)} + \omega B_1 \mathbf{x}^{(k+1)} + \omega B_2 \mathbf{x}^{(k)} + \omega \mathbf{c}.$$

Как нетрудно видеть, при  $\omega = 1$  метод релаксации совпадает с методом Зейделя. При  $\omega > 1$  его было принято называть *методом последовательной верхней релаксации*, а при  $\omega < 1$  — *методом последовательной нижней релаксации*. В последнее время метод релаксации называют методом последовательной верхней релаксации для любых значений  $\omega$ .

Если  $A$  — симметричная положительно определенная матрица, то при любом значении параметра  $\omega$  ( $0 < \omega < 2$ ) метод релаксации сходится. Часто оказывается возможным выбрать параметр  $\omega > 1$  так, чтобы SOR-метод сходился существенно быстрее, чем методы Якоби и Зейделя. Однако выбор параметра релаксации — довольно трудная задача. Во многих случаях она решается экспериментальным путем.

Существуют различные модификации метода релаксации. Распространенный вариант метода связан с использованием различных параметров  $\omega_i$  для вычисления различных компонент  $x_i$  очередного  $(k + 1)$ -го приближения к решению.

**Пример 6.3.** Используя метод последовательной верхней релаксации с параметром  $\omega = 1.12$ , найдем решение системы (6.15) с точностью  $\epsilon = 10^{-3}$ .

Приведем систему к виду (6.16), положим  $x^{(0)} = (0, 0, 0)^T$  и будем вычислять последовательные приближения по формулам:

$$\begin{aligned}x_1^{(k+1)} &= (1 - \omega)x_1^{(k)} + \omega(0.16x_2^{(k)} - 0.08x_3^{(k)} + 1.2), \\x_2^{(k+1)} &= \omega \cdot 0.2x_1^{(k+1)} + (1 - \omega)x_2^{(k)} + \omega(-0.424x_3^{(k)} - 1.736), \\x_3^{(k+1)} &= \omega(-0.1389x_1^{(k+1)} - 0.5889x_2^{(k+1)}) + (1 - \omega)x_3^{(k)} - \omega \cdot 0.6667.\end{aligned}$$

Значения приближений с четырьмя цифрами после десятичной точки приведены в табл. 6.3.

Т а б л и ц а 6.3

$n$	0	1	2	3	4	5
$x_1^{(n)}$	0.0000	1.3440	0.8166	0.8094	0.7995	0.8001
$x_2^{(n)}$	0.0000	-1.6433	-1.9442	-1.9973	-1.9998	-2.0000
$x_3^{(n)}$	0.0000	0.8001	0.9846	0.9986	1.0001	1.0000

Сравнение с точным решением  $x_1 = 0.8$ ,  $x_2 = -2$ ,  $x_3 = 1$  показывает, что для получения приближения к решению с точностью  $\epsilon = 10^{-3}$  потребовалось всего 4 итерации. Напомним, что для достижения той же точности при том же начальном приближении методами Якоби и Зейделя потребовалось соответственно 13 и 7 итераций.

#### § 6.4. Дополнительные замечания

1. При изложении итерационных методов решения систем линейных алгебраических уравнений нам пришлось ограничиться простейшими методами. В данной главе оказались не рассмотренными такие известные и популярные методы, как *метод наискорейшего спуска*, *метод сопряженных градиентов* (называемый еще *методом Ланцоша*<sup>1</sup>), *метод минимальных невязок*, *линейный многоступенчатый метод с чебышевским набором параметров* и др. Эти методы изложены, например, в учебниках [9], [71] и в специальной литературе [20], [72], [89]. Отметим, что методы наискорейшего спуска и сопряженных градиентов будут рассмотрены в гл. 10 в связи с задачей минимизации квадратичной функции (6.31).

<sup>1</sup> Корнелий Ланцош (1893 — 1974) — физик-теоретик и математик. Родился в Венгрии. Работал в Германии, США, Ирландии.

2. Многие итерационные методы решения систем с симметричными положительно определенными матрицами основаны на замене задачи отыскания решения системы  $Ax = b$  эквивалентной задачей отыскания минимума квадратичной функции

$$\Phi(x) = \frac{1}{2} (Ax, x) - (b, x). \quad (6.31)$$

В частности, метод Зейделя дает ту же последовательность приближений, что и метод покоординатного спуска, примененный к функции (6.31). Подробнее об этом будет сказано в § 10.2; см. также [9].

3. В настоящее время наиболее глубоко развиты методы решения систем уравнений с симметричными положительно определенными матрицами. Иногда этого достаточно, так как в принципе существует возможность симметризовать любую систему  $Ax = b$  с невырожденной квадратной матрицей, т.е. свести ее к эквивалентной системе с симметричной положительно определенной матрицей. Для этого можно умножить обе части системы на матрицу  $A^T$ . В полученной таким образом системе

$$A^T A x = A^T b \quad (6.32)$$

матрица  $\tilde{A} = A^T A$  обладает всеми нужными свойствами.

Однако указанным образом поступают сравнительно редко. Дело в том, что при переходе от  $A$  к  $\tilde{A}$  может быть потеряно свойство разреженности. Кроме того, вообще говоря, существенно ухудшается обусловленность системы. Например, для матриц, близких к симметричным,  $\text{cond}(\tilde{A}) \approx (\text{cond}(A))^2$ . Следовательно, имеется реальная опасность, что система (6.32) окажется очень плохо обусловленной.

4. Как уже было отмечено, одно из важнейших достоинств итерационных методов заключается в возможности эффективного использования разреженности матрицы  $A$ . Поясним сказанное на примере метода простой итерации.

В случае когда матрица  $B$  — заполненная, для вычисления по формуле (6.6) требуется выполнить примерно  $2m^2$  арифметических операций. Однако для разреженной матрицы с  $M$  ( $M \ll m^2$ ) ненулевыми элементами требуется лишь примерно  $2M$  арифметических операций (одно умножение и одно сложение на каждый ненулевой элемент). Таким образом, общее число операций составляет примерно  $2Mn(\epsilon)$ , где  $n(\epsilon)$  — число итераций, необходимое для достижения заданной точности  $\epsilon$ .

# МЕТОДЫ ОТЫСКАНИЯ РЕШЕНИЙ СИСТЕМ НЕЛИНЕЙНЫХ УРАВНЕНИЙ

Будем считать, что в множестве  $m$ -мерных векторов введена некоторая норма, порождающая соответствующую норму для квадратных матриц порядка  $m$  (см. § 5.2).

1. **Постановка задачи.** Задача отыскания решения системы нелинейных уравнений с  $m$  неизвестными вида

является существенно более сложной, чем рассмотренная в гл. 4 задача отыскания решения уравнения с одним неизвестным. Однако на практике она встречается значительно чаще, так как в реальных исследованиях интерес представляет, как правило, определение не одного, а нескольких параметров (нередко их число доходит до сотен и тысяч).

191

летворяющий уравнениям (7.1), практически невозможно. В отличие от случая решения систем линейных алгебраических уравнений использование прямых методов здесь исключается. Единственно реальный путь решения системы (7.1) состоит в использовании итерационных методов для получения приближенного решения  $\mathbf{x}^* = (x_1^*, x_2^*, \dots, x_m^*)^T$ , удовлетворяющего при заданном  $\varepsilon > 0$  неравенству  $\|\mathbf{x}^* - \bar{\mathbf{x}}\| < \varepsilon$ .

Прежде чем перейти к изучению методов решения системы (7.1), подчеркнем важность понимания того факта, что эта задача может вообще не иметь решения, а в случае, когда решения существуют, их число может быть произвольным. В общем случае весьма сложно выяснить, имеет ли система решения и сколько их.

**Пример 7.1.** Рассмотрим систему уравнений

$$4x_1^2 + x_2^2 = 4,$$

$$x_2 - x_2^2 + t = 0.$$

Здесь  $x_1, x_2$  — неизвестные,  $t$  — параметр. Первое уравнение задает на плоскости  $Ox_1Ox_2$  эллипс, второе уравнение — параболу. Координаты точек пересече-

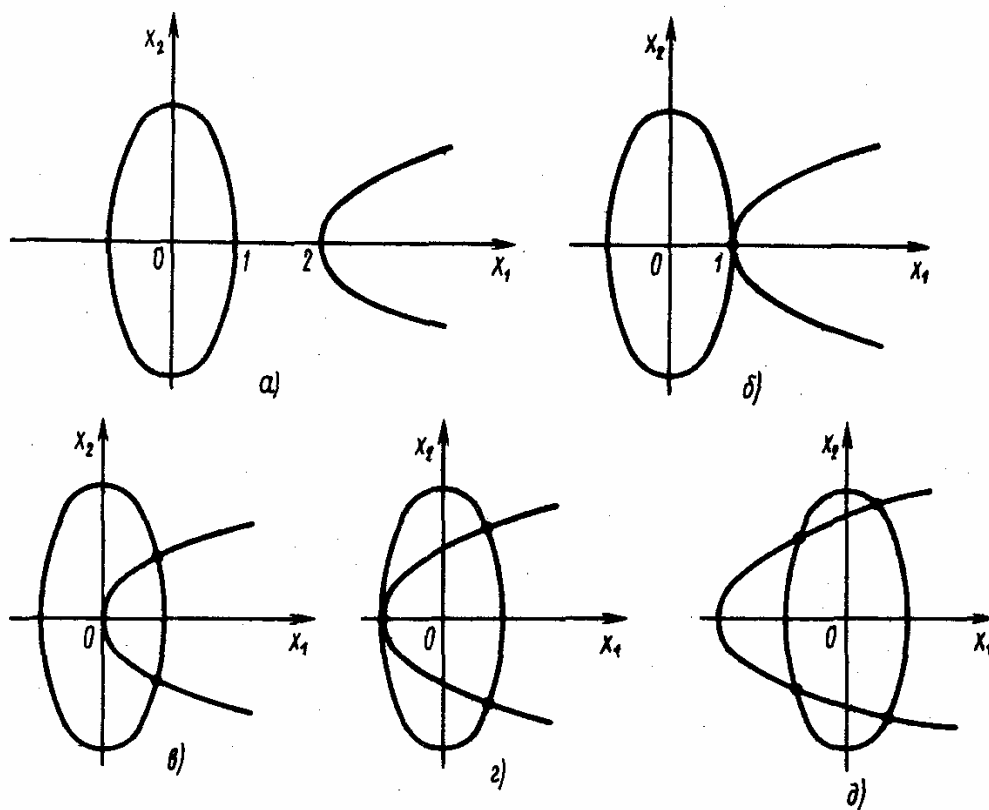


Рис. 7.1

ния этих кривых дают решения системы. Если значения параметра  $t$  изменяются от  $-2$  до  $2$ , то возможны следующие ситуации (рис. 7.1): а)  $t = -2$  — решений нет; б)  $t = -1$  — одно решение; в)  $t = 0$  — два решения; г)  $t = 1$  — три решения; д)  $t = 2$  — четыре решения.

Для дальнейшего удобно использовать сокращенную векторную форму записи систем. Наряду с вектором неизвестных  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$  рассмотрим вектор-функцию  $\mathbf{f} = (f_1, f_2, \dots, f_m)^T$ . В этих обозначениях система (7.1) примет вид

$$\mathbf{f}(\mathbf{x}) = 0. \quad (7.2)$$

Будем считать функции  $f_i(\mathbf{x})$  непрерывно дифференцируемыми в некоторой окрестности решения  $\bar{\mathbf{x}}$ . Введем для системы функций  $f_1, f_2, \dots, f_m$  матрицу Якоби

$$\mathbf{f}'(\mathbf{x}) = \begin{bmatrix} \frac{\partial f_1(\mathbf{x})}{\partial x_1} & \frac{\partial f_1(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial f_1(\mathbf{x})}{\partial x_m} \\ \frac{\partial f_2(\mathbf{x})}{\partial x_1} & \frac{\partial f_2(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial f_2(\mathbf{x})}{\partial x_m} \\ \dots & \dots & \dots & \dots \\ \frac{\partial f_m(\mathbf{x})}{\partial x_1} & \frac{\partial f_m(\mathbf{x})}{\partial x_2} & \dots & \frac{\partial f_m(\mathbf{x})}{\partial x_m} \end{bmatrix}, \quad (7.3)$$

которая будет использована в дальнейшем.

**2. Основные этапы решения.** Как и в случае уравнения с одним неизвестным (см. гл. 4), отыскание решений начинают с этапа локализации. Для каждого из искомых решений  $\bar{\mathbf{x}}$  указывают множество, которое содержит только одно это решение и расположено в достаточно малой его окрестности. Часто в качестве такого множества выступает параллелепипед или шар в  $m$ -мерном пространстве.

Иногда этап локализации не вызывает затруднений; соответствующие множества могут быть заданными, определяться из физических соображений, из смысла параметров  $x_i$  либо быть известными из опыта решений подобных задач. Однако чаще всего задача локализации (в особенности при больших  $m$ ) представляет собой сложную проблему, от успешного решения которой в основном и зависит возможность вычисления решений системы (7.1). На этапе локализации особое значение приобретают квалификация исследователя, понимание им существа решаемой научной или инженерной проблемы, опыт решения этой или близких задач на ЭВМ. Во многих случаях полное решение задачи локализации невозможно и ее можно считать решенной удовлетворительно, если для  $\bar{\mathbf{x}}$  удастся найти хорошее начальное прибли-

жение  $\mathbf{x}^{(0)}$ . В простейших случаях (например, для системы двух уравнений с двумя неизвестными) могут быть использованы графические методы (см. пример 7.1).

На втором этапе для вычисления решения с заданной точностью  $\varepsilon$  используют один из итерационных методов решения нелинейных систем.

Будем считать, что определения § 4.1, связанные с характеристикой сходимости итерационных методов, остаются в силе, причем в неравенствах (4.5) и (4.6) знак модуля заменен на знак нормы, а  $\delta$ -окрестность решения  $\bar{\mathbf{x}}$  понимается как множество точек  $\mathbf{x}$ , удовлетворяющих условию  $\|\mathbf{x} - \bar{\mathbf{x}}\| < \delta$ .

**Пример 7.1.** Произведем локализацию решений системы

$$\begin{aligned} x_1^3 + x_2^3 &= 8x_1x_2, \\ x_1 \ln x_2 &= x_2 \ln x_1. \end{aligned} \quad (7.4)$$

На плоскости  $x_1 O x_2$  построим графики уравнений системы. График первого уравнения — это лист Декарта<sup>1</sup> (рис. 7.2, а). График второго уравнения состоит из луча — биссектрисы первого координатного угла и кривой, пересекающей эту биссектрису в точке  $(e, e)^T$  (рис. 7.2, б).

Из рис. 7.3 видно, что эти кривые пересекаются в трех точках  $A, B, C$ , т.е. система имеет три решения. Так как оба графика симметричны относительно прямой  $x_1 = x_2$ , то координаты точки  $B$  равны и их легко вычислить:  $x_1 = 4$ ,  $x_2 = 4$ . В силу этой же симметрии достаточно определить только координаты  $\bar{x}_1, \bar{x}_2$  точки  $C$ , так как точка  $A$  имеет координаты  $x_1 = \bar{x}_2$  и  $x_2 = \bar{x}_1$ . Из рис. 7.3 замечаем, что точка  $C$  содержится в прямоугольнике  $\Pi = \{(x, y) : 3.5 \leq x_1 \leq 4, 1.5 \leq x_2 \leq 2.5\}$  и  $\bar{x}_1 \approx 3.8$ ,  $\bar{x}_2 \approx 2$ .

Подчеркнем, что только по виду уравнений системы (7.4) без использования графического метода установить число решений и найти приближения к ним было бы весьма трудно. К сожалению, при числе уравнений  $m > 3$  геометрические иллюстрации теряют свою эффективность.

**З а м е ч а н и е.** Иногда удается понизить порядок  $m$  системы, выразив одно или несколько неизвестных из одних уравнений системы и подставив соответствующие выражения в другие уравнения.

---

<sup>1</sup> Рене Декарт (1596 — 1650) — французский философ, математик, физик, физиолог. Впервые ввел понятие переменной величины и функции. В аналитической геометрии создал метод прямоугольных координат.

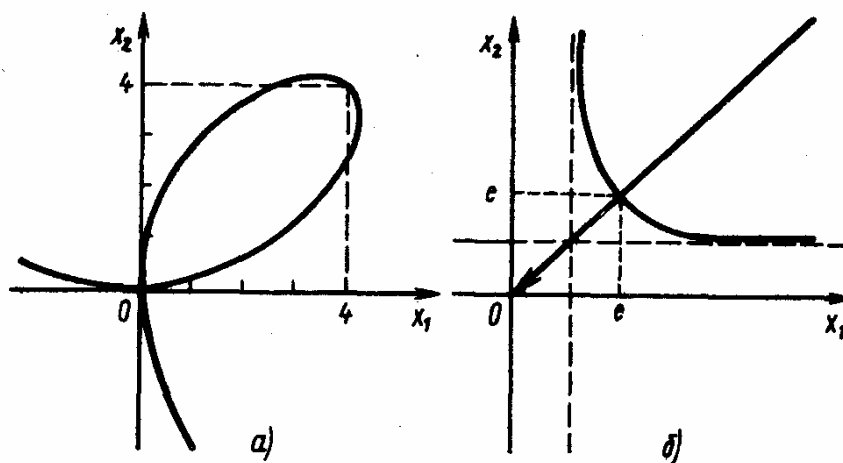


Рис. 7.2

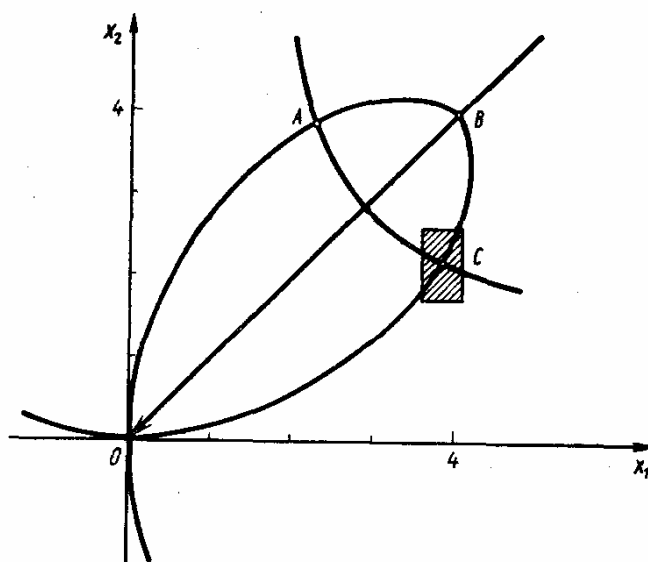


Рис. 7.3

**Пример 7.2.** Система уравнений

$$x^3 + y^3 = 8xy,$$

$$x \ln y = \ln x$$

сводится к одному нелинейному уравнению  $x^3 + x^{\frac{3}{x}} = 8 x^{1+\frac{1}{x}}$  после того, как из второго уравнения выражается  $y = x^{\frac{1}{x}}$ .

**3. Корректность и обусловленность задачи.** Будем считать, что система (7.1) имеет решение  $\bar{x}$ , причем в некоторой окрестности этого







**З а м е ч а н и е 1.** Условие (7.8), грубо говоря, означает, что в окрестности решения производные  $\frac{\partial \varphi_i}{\partial x_j}$  для всех  $i$  и  $j$  должны быть "достаточно малы по модулю". Иными словами, систему (7.1) следует преобразовать к такому виду (7.5), чтобы функции  $\varphi_i$  слабо менялись при изменении аргументов, т.е. были "почти постоянными". Каких-либо общих рецептов, как это следует делать, в общем случае нет.

**З а м е ч а н и е 2.** В условиях теоремы 7.1 верна апостериорная оценка погрешности

$$\|\mathbf{x}^{(n)} - \bar{\mathbf{x}}\| \leq \frac{q}{1 - q} \|\mathbf{x}^{(n)} - \mathbf{x}^{(n-1)}\|, \quad (7.10)$$

которая удобна для формулирования критерия окончания итераций, если известна величина  $q$ . Однако найти значение  $q$ , удовлетворяющее неравенству (7.8) для всех  $\mathbf{x}$  из некоторой  $\sigma$ -окрестности корня, далеко не просто. В ряде случаев при наличии достаточно хорошего начального приближения  $\mathbf{x}^{(0)}$  можно, считая, что  $q \approx q_0 = \|\varphi'(\mathbf{x}^{(0)})\|$ , использовать следующий практический критерий окончания итерационного процесса:

$$\|\mathbf{x}^{(n)} - \mathbf{x}^{(n-1)}\| \leq \varepsilon_1 = \frac{1 - q_0}{q_0} \varepsilon.$$

**Пример 7.3.** Используя метод простой итерации, найдем с точностью  $\varepsilon = 10^{-3}$  решение  $\bar{x}_1, \bar{x}_2$  системы (7.4).

Приведем систему к виду, удобному для итераций:

$$x_1 = \sqrt[3]{8x_1x_2 - x_2^3},$$

$$x_2 = x_2 + \frac{x_2}{\ln x_2} - \frac{x_1}{\ln x_1}.$$

Здесь  $\varphi_1(x_1, x_2) = \sqrt[3]{8x_1x_2 - x_2^3}$ ,  $\varphi_2(x_1, x_2) = x_2 + \frac{x_2}{\ln x_2} - \frac{x_1}{\ln x_1}$ . Проверим выполнение условия сходимости вблизи точки  $C$ . Вычислим матрицу Якоби

$$\varphi'(\mathbf{x}, \mathbf{x}_2) = \begin{bmatrix} \frac{\partial \varphi_1}{\partial x_1} & \frac{\partial \varphi_1}{\partial x_2} \\ \frac{\partial \varphi_2}{\partial x_1} & \frac{\partial \varphi_2}{\partial x_2} \end{bmatrix} = \begin{bmatrix} \frac{8x_2}{3(8x_1x_2 - x_2^3)^{2/3}} & \frac{8x_1 - 3x_2^2}{3(8x_1x_2 - x_2^3)^{2/3}} \\ \frac{1}{\ln^2 x_1} - \frac{1}{\ln x_1} & 1 + \frac{1}{\ln x_2} - \frac{1}{\ln^2 x_2} \end{bmatrix}.$$

Так как  $\bar{x}_1 \approx 3.8$  и  $\bar{x}_2 \approx 2$ , то для  $x \approx \bar{x}$  имеем

$$\varphi'(x_1, x_2) \approx \varphi'(3.8; 2) \approx \begin{bmatrix} 0.379 & 0.436 \\ -0.188 & 0.361 \end{bmatrix}.$$

Тогда  $\|\varphi'(x_1, x_2)\|_\infty \approx \|\varphi'(3.8, 2)\|_\infty \approx 0.379 + 0.436 = 0.815$ . Следовательно, метод простой итерации

$$x_1^{(k+1)} = \sqrt[3]{8x_1^{(k)}x_2^{(k)} - (x_2^{(k)})^3}, \quad (7.11)$$

$$x_2^{(k+1)} = x_2^{(k)} + \frac{x_2^{(k)}}{\ln x_2^{(k)}} - \frac{x_1^{(k)}}{\ln x_1^{(k)}}$$

будет сходиться со скоростью геометрической прогрессии, знаменатель которой примерно равен 0.815, если начальные приближения брать в достаточно малой окрестности решения.

Возьмем  $x_1^{(0)} = 3.8$ ,  $x_2^{(0)} = 2$  и будем вести итерации по формулам (7.11), используя критерий окончания (7.10), в котором  $\varepsilon = 10^{-3}$ ,  $q = 0.815$ . Результаты вычислений с шестью знаками мантиссы приведены в табл. 7.1.

Т а б л и ц а 7.1

$k$	0	1	2	3	4
$x_1^{(k)}$	3.80000	3.75155	3.74960	3.75892	3.76720
$x_2^{(k)}$	2.00000	2.03895	2.06347	2.07498	2.07883
$k$	5	6	7	8	9
$x_1^{(k)}$	3.77198	3.77399	3.77450	3.77440	3.77418
$x_2^{(k)}$	2.07920	2.07850	2.07778	2.07732	2.07712

При  $k = 9$  критерий окончания выполняется и можно положить  $\bar{x}_1 = 3.774 \pm \pm 0.001$ ,  $\bar{x}_2 = 2.077 \pm 0.001$ .

**3. Влияние погрешности вычислений.** В силу наличия погрешностей при вычислении на ЭВМ получается не последовательность  $\mathbf{x}^{(k)}$ , удовлетворяющая равенству (7.7), а последовательность  $\tilde{\mathbf{x}}^{(k)}$ , удовлетворяющая равенству

$$\tilde{\mathbf{x}}^{(k+1)} = \varphi^*(\tilde{\mathbf{x}}^{(k)}). \quad (7.12)$$

Будем считать, что абсолютная погрешность вычисляемых значений  $\varphi^*(\mathbf{x})$  вектор-функции  $\varphi$  мала и что  $\|\varphi(\mathbf{x}) - \varphi^*(\mathbf{x})\| \leq \bar{\Delta}(\varphi^*)$ . Наличие погрешности вычисления  $\varphi$  приводит к появлению области неопределенности решения  $\bar{\mathbf{x}}$ , радиус  $\bar{\epsilon}$  которой можно приближенно оценить, пользуясь неравенством  $\bar{\epsilon} \leq \bar{\epsilon}^* = \bar{\Delta}(\varphi^*)/(1 - q)$  в том случае, если  $\|\varphi'(\mathbf{x})\| \leq q$ .

Сформулируем следующий результат, являющийся аналогом теорем 4.5 и 6.2.

**Теорема 7.2.** Пусть выполнены условия теоремы 7.1 и для всех  $\mathbf{x}$  из  $\sigma$ -окрестности решения  $\bar{\mathbf{x}}$  выполнено неравенство  $\|\varphi(\mathbf{x}) - \varphi^*(\mathbf{x})\| \leq \bar{\Delta}(\varphi^*)$ . Предположим, также что  $\bar{\epsilon}^* = \frac{\bar{\Delta}(\varphi^*)}{1 - q} < \sigma$  (т.е. величина  $\bar{\Delta}(\varphi^*)$  достаточно мала). Тогда если вычисления по формулам (7.7) и (7.12) начинаются с одного начального приближения  $\mathbf{x}^{(0)} = \tilde{\mathbf{x}}^{(0)}$ , принадлежащего  $\sigma_1$ -окрестности решения  $\bar{\mathbf{x}}$  (где  $\sigma_1 = \min \{\sigma, (\sigma - \bar{\epsilon}^*)/q\}$ ), то последовательность  $\tilde{\mathbf{x}}^{(n)}$  не выходит за пределы  $\sigma$ -окрестности решения  $\bar{\mathbf{x}}$  и для всех  $n \geq 1$  справедливы оценки

$$\|\mathbf{x}^{(n)} - \tilde{\mathbf{x}}^{(n)}\| \leq \bar{\epsilon}^*,$$

$$\|\tilde{\mathbf{x}}^{(n)} - \bar{\mathbf{x}}\| \leq q^n \|\tilde{\mathbf{x}}^{(0)} - \bar{\mathbf{x}}\| + \bar{\epsilon}^*,$$

$$\|\tilde{\mathbf{x}}^{(n)} - \bar{\mathbf{x}}\| \leq \frac{q}{1 - q} \|\tilde{\mathbf{x}}^{(n)} - \tilde{\mathbf{x}}^{(n-1)}\| + \bar{\epsilon}^*.$$

**4. Модификации метода простой итерации.** В некоторых случаях для ускорения сходимости полезно использовать следующий аналог метода Зейделя (см. § 6.2):



Предположим, что исходя из начального приближения  $\mathbf{x}^{(0)}$  к решению  $\bar{\mathbf{x}}$  построены приближения  $\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(n)}$ . Заменим в системе (7.1) каждую из функций  $f_i (i = 1, 2, \dots, m)$  линейной частью ее разложения по формуле Тейлора в точке  $\mathbf{x}^{(n)}$ :

$$f_i(\mathbf{x}) \approx f_i(\mathbf{x}^{(n)}) + \sum_{j=1}^m \frac{\partial f_i(\mathbf{x}^{(n)})}{\partial x_j} (x_j - x_j^{(n)}).$$

В результате приходим к системе линейных алгебраических уравнений

$$\begin{aligned} f_1(\mathbf{x}^{(n)}) + \sum_{j=1}^m \frac{\partial f_1(\mathbf{x}^{(n)})}{\partial x_j} (x_j - x_j^{(n)}) &= 0, \\ f_2(\mathbf{x}^{(n)}) + \sum_{j=1}^m \frac{\partial f_2(\mathbf{x}^{(n)})}{\partial x_j} (x_j - x_j^{(n)}) &= 0, \\ . &. . . . . \\ f_m(\mathbf{x}^{(n)}) + \sum_{j=1}^m \frac{\partial f_m(\mathbf{x}^{(n)})}{\partial x_j} (x_j - x_j^{(n)}) &= 0, \end{aligned}$$

имеющей в матричной форме записи следующий вид:

$$f(\mathbf{x}^{(n)}) + f'(\mathbf{x}^{(n)})(\mathbf{x} - \mathbf{x}^{(n)}) = 0. \quad (7.13)$$

Здесь  $f'$  — матрица Якоби (7.3).

Предположим, что матрица  $f'(\mathbf{x}^{(n)})$  невырожденная, т.е. существует обратная матрица  $(f'(\mathbf{x}^{(n)}))^{-1}$ . Тогда система (7.13) имеет единственное решение, которое и принимается за очередное приближение  $\mathbf{x}^{(n+1)}$  к решению  $\bar{\mathbf{x}}$ . Таким образом, приближение  $\mathbf{x}^{(n+1)}$  удовлетворяет равенству

$$f(\mathbf{x}^{(n)}) + f'(\mathbf{x}^{(n)})(\mathbf{x}^{(n+1)} - \mathbf{x}^{(n)}) = 0, \quad (7.14)$$

выражая из которого  $\mathbf{x}^{(n+1)}$ , выводим итерационную формулу метода Ньютона:

$$\mathbf{x}^{(n+1)} = \mathbf{x}^{(n)} - (f'(\mathbf{x}^{(n)}))^{-1} f(\mathbf{x}^{(n)}). \quad (7.15)$$

**З а м е ч а н и е.** Формула (7.15) предполагает использование трудоемкой операции обращения матрицы (см. гл. 5), поэтому непосредственное ее использование для вычисления  $\mathbf{x}^{(n+1)}$  в большинстве случаев нецелесообразно. Обычно вместо этого решают эквивалентную системе (7.14) систему линейных алгебраических уравнений

$$f'(\mathbf{x}^{(n)})\Delta\mathbf{x}^{(n+1)} = -f(\mathbf{x}^{(n)}) \quad (7.16)$$

относительно поправки  $\Delta\mathbf{x}^{(n+1)} = \mathbf{x}^{(n+1)} - \mathbf{x}^{(n)}$ . Затем полагают

$$\mathbf{x}^{(n+1)} = \mathbf{x}^{(n)} + \Delta\mathbf{x}^{(n+1)}. \quad (7.17)$$

**2. Сходимость метода.** Сформулируем основную теорему о сходимости метода Ньютона.

**Т е о р е м а 7.3.** Пусть в некоторой окрестности решения  $\bar{\mathbf{x}}$  системы (7.1) функции  $f_i (i = 1, 2, \dots, m)$  дважды непрерывно дифференцируемы и матрица  $f'(\bar{\mathbf{x}})$  невырождена. Тогда найдется такая малая  $\delta$ -окрестность решения  $\bar{\mathbf{x}}$ , что при произвольном выборе начального приближения  $\mathbf{x}^{(0)}$  из этой окрестности итерационная последовательность метода Ньютона не выходит за пределы окрестности и справедлива оценка:

$$\|\mathbf{x}^{(n+1)} - \bar{\mathbf{x}}\| \leq \delta^{-1} \|\mathbf{x}^{(n)} - \bar{\mathbf{x}}\|^2, \quad n \geq 0.$$

Эта оценка означает, что метод сходится с квадратичной скоростью.

Квадратичная скорость сходимости метода Ньютона позволяет использовать простой практический критерий окончания:

$$\|\mathbf{x}^{(n)} - \mathbf{x}^{(n-1)}\| < \varepsilon. \quad (7.18)$$

**Пример 7.3.** Используя метод Ньютона, найдем с точностью  $\varepsilon = 10^{-4}$  решение  $\bar{x}_1, \bar{x}_2$  системы (7.4).

Возьмем  $x_1^{(0)} = 3.8, x_2^{(0)} = 2$  и будем вести вычисления по формулам (7.16), (7.17), в которых

$$f(\mathbf{x}) = \begin{bmatrix} x_1^3 + x_2^3 - 8x_1x_2 \\ x_1 \ln x_2 - x_2 \ln x_1 \end{bmatrix}, \quad f'(\mathbf{x}) = \begin{bmatrix} 3x_1^2 - 8x_2 & 3x_2^2 - 8x_1 \\ \ln x_2 - \frac{x_2}{x_1} & \frac{x_1}{x_2} - \ln x_1 \end{bmatrix}.$$

Результаты вычислений с шестью знаками мантиссы приведены в табл. 7.2.

Т а б л и ц а 7.2

$k$	0	1	2	3
$x_1^{(k)}$	3.80000	3.77258	3.77388	3.77389
$x_2^{(k)}$	2.00000	2.07189	2.07708	2.07710



При  $k = 3$  критерий окончания  $\|x^{(k)} - x^{(k-1)}\|_{\infty} < \varepsilon = 10^{-4}$  выполняется и можно положить  $\bar{x}_1 = 3.7739 \pm 0.0001$ ,  $\bar{x}_2 = 2.0771 \pm 0.0001$ .

**3. Трудности использования.** Изложенные в § 4.6 трудности использования метода Ньютона не только сохраняются при применении его к решению систем нелинейных уравнений, но и усугубляются. Во-первых, возникает проблема вычисления на каждой итерации матрицы  $f'(x)$  из  $m^2$  частных производных, что само по себе может оказаться весьма сложным делом. Во-вторых, обостряется проблема нахождения хорошего начального приближения. Ее решить в многомерном случае гораздо труднее, чем в одномерном.

**4. Влияние погрешности вычислений.** Пусть  $f^*$  и  $(f')^*$  — вычисляемые на ЭВМ приближенные значения вектор-функции  $f$  и матрицы Якоби  $f'$ . Пусть для решения системы линейных алгебраических уравнений используется схема частичного выбора (см. § 5.5). Будем считать, что матрица  $f'$  достаточно хорошо обусловлена ( $\text{cond}(f') \varepsilon_M \ll 1$ ) и вычисляется не слишком грубо ( $\|f' - (f')^*\| \ll \|f'\|$ ). Тогда при выборе начального приближения из малой окрестности решения метод Ньютона является устойчивым и дает возможность найти решение с гарантированной точностью  $\varepsilon \geq \bar{\varepsilon}^* = \|(f'(\bar{x}))^{-1}\| \Delta(f^*)$ .

#### § 7.4. Модификации метода Ньютона

Если оценивать качество метода Ньютона только по числу необходимых итераций, то следовало бы сделать вывод о том, что этот метод стоит применять всегда, когда он сходится. На практике для достижения разумной точности  $\varepsilon$  при выборе достаточно хорошего начального приближения  $x^{(0)}$  требуется, как правило, 3—5 итераций.

Однако при оценке общей трудоемкости метода следует учитывать, что на каждой итерации требуется выполнение следующей дополнительной работы:

- 1) вычисление  $m$  компонент вектора  $f(x^{(n)})$ ;
- 2) вычисление  $m^2$  компонент матрицы Якоби  $f'(x^{(n)})$ ;
- 3) решение системы линейных алгебраических уравнений (7.16).

Существует большое число модификаций метода Ньютона, позволяющих в тех или иных ситуациях снизить его трудоемкость либо избежать необходимости вычисления производных. Рассмотрим кратко некоторые из таких модификаций, учитывая, что их одномерные наложения были изучены более подробно в § 4.7.

**1. Упрощенный метод Ньютона.** Заменяем в расчетных формулах метода Ньютона (7.16), (7.17) матрицу  $f'(\mathbf{x}^{(n)})$ , зависящую от  $n$ , постоянной матрицей  $A = f'(\mathbf{x}^{(0)})$ . В результате получим расчетные формулы упрощенного метода Ньютона:

$$A\Delta\mathbf{x}^{(n+1)} = -f(\mathbf{x}^{(n)}), \quad (7.19)$$

$$\mathbf{x}^{(n+1)} = \mathbf{x}^{(n)} + \Delta\mathbf{x}^{(n+1)}. \quad (7.20)$$

Можно показать, что этот метод сходится со скоростью геометрической прогрессии, если начальное приближение  $\mathbf{x}^{(0)}$  выбрано достаточно близким к решению  $\bar{\mathbf{x}}$ , причем знаменатель прогрессии  $q$  тем меньше, чем ближе  $\mathbf{x}^{(0)}$  к  $\bar{\mathbf{x}}$ .

По сравнению с методом Ньютона число итераций, необходимое для достижения заданной точности  $\epsilon$ , существенно возрастает. Тем не менее общие вычислительные затраты могут оказаться меньше. Причины этого состоят в следующем. Во-первых, вычисление матрицы Якоби производится здесь только один раз; во-вторых, как нетрудно видеть, при использовании упрощенного метода Ньютона (7.19), (7.20) многократно решается система линейных уравнений с фиксированной матрицей  $A$  и различными правыми частями. Это означает, что при решении систем (7.19) методом Гаусса возможно применение LU-разложения матрицы  $A$ , которое резко уменьшает число операций, необходимых для вычисления  $\Delta\mathbf{x}^{(n+1)}$  (см. гл. 5).

**2. Использование формул численного дифференцирования.** Довольно часто вычисление производных  $\frac{\partial f_i}{\partial x_j}$ , являющихся элементами матрицы  $f'$ , затруднено или вообще невозможно. В такой ситуации для приближенного вычисления производных можно попытаться использовать формулы численного дифференцирования (см. гл. 12). Например, можно использовать следующую конечно-разностную аппроксимацию производной:

$$\begin{aligned} \frac{\partial f_i}{\partial x_j}(\mathbf{x}^{(n)}) \approx J_{ij}^{(n)} = \frac{1}{h_j^{(n)}} (f_i(x_1^{(n)}, \dots, x_{j-1}^{(n)}, x_j^{(n)} + h_j^{(n)}, x_{j+1}^{(n)}, \dots, x_m^{(n)}) - \\ - f_i(x_1^{(n)}, \dots, x_m^{(n)})). \end{aligned}$$

Параметры  $h_j^{(n)} \neq 0$  ( $j = 1, 2, \dots, m$ ) — это конечно-разностные шаги.

Если в расчетных формулах метода Ньютона (7.16), (7.17) заменить матрицу  $f'(\mathbf{x}^{(n)})$  аппроксимирующей ее матрицей  $J^{(n)}$  с элементами  $J_{ij}^{(n)}$ , то получим следующий итерационный метод:

$$J^{(n)} \Delta \mathbf{x}^{(n+1)} = -f(\mathbf{x}^{(n)}), \quad (7.22)$$

$$\mathbf{x}^{(n+1)} = \mathbf{x}^{(n)} + \Delta \mathbf{x}^{(n+1)}. \quad (7.23)$$

В простейшем варианте этого метода шаги  $h_j$  ( $j = 1, 2, \dots, m$ ) не зависят от  $n$ . Отметим, что выбор величины шагов представляет собой не очень простую задачу. С одной стороны, они должны быть достаточно малыми, чтобы матрица  $J^{(n)}$  хорошо приближала матрицу  $f'(\mathbf{x}^{(n)})$ , с другой, они не могут быть очень малы, так как в этом случае влияние погрешностей вычисления функций  $f_j$  на погрешность формулы (7.21) численного дифференцирования становится катастрофическим (выполняется вычитание близких приближенных чисел).

Следующие три метода можно рассматривать как варианты метода (7.22), (7.23), в которых реализованы специальные подходы к вычислению вектора  $\mathbf{h}^{(n)} = (h_1^{(n)}, h_2^{(n)}, \dots, h_m^{(n)})^T$ . Для того чтобы приведенные ниже рассуждения были формально корректными, в формуле (7.21) положим  $J_{ij}^{(n)} = \frac{\partial f_i}{\partial x_j}(\mathbf{x}^{(n)})$ , если оказалось, что  $h_j^{(n)} = 0$ .

**3. Метод ложного положения.** Пусть  $\mathbf{c}$  — фиксированный вектор. Положим  $\mathbf{h}^{(n)} = \mathbf{c} - \mathbf{x}^{(n)}$ . Тогда формулы (7.21) — (7.23) определяют *метод ложного положения*, обладающий линейной скоростью сходимости в случае, если вектор  $\mathbf{c}$  и начальное приближение  $\mathbf{x}^{(0)}$  выбраны достаточно близко к решению.

**4. Метод секущих.** В одном из наиболее популярных своих вариантов *метод секущих* можно рассматривать как метод (7.21) — (7.23), где  $\mathbf{h}^{(n)} = \mathbf{x}^{(n-1)} - \mathbf{x}^{(n)}$ . Метод секущих является двухшаговым: для вычисления очередного приближения  $\mathbf{x}^{(n+1)}$  используют два предыдущих приближения  $\mathbf{x}^{(n)}$  и  $\mathbf{x}^{(n-1)}$ . Для того чтобы начать вычисления, необходимо задать два начальных приближения  $\mathbf{x}^{(0)}$  и  $\mathbf{x}^{(1)}$ .

При удачном выборе начальных приближений  $\mathbf{x}^{(0)}$  и  $\mathbf{x}^{(1)}$  метод секущих сходится со сверхлинейной скоростью с порядком сходимости  $p = (\sqrt{5} + 1)/2$ .

**5. Метод Стеффенсена.** Вычисления по *методу Стеффенсена* производят по формулам (7.21) — (7.23), где  $\mathbf{h}^{(n)} = f(\mathbf{x}^{(n)})$ .

Замечательно то, что хотя этот метод не требует вычисления произ-

водных и в отличие от метода секущих является одношаговым, он, как и метод Ньютона, обладает свойством квадратичной сходимости. Правда, как и в методе Ньютона, его применение затруднено необходимостью выбора хорошего начального приближения.

По-видимому, для решения нелинейных систем вида (7.1) метод Стеффенсена чаще окажется лучшим выбором, чем метод секущих или метод ложного положения.

Как и в одномерном случае (см. § 4.7), следует отметить, что методы секущих и Стеффенсена теряют устойчивость вблизи решения (фактически это происходит при попадании приближения  $\mathbf{x}^{(n)}$  в область неопределенности решения  $\bar{\mathbf{x}}$ ). Поэтому при использовании этих методов важно вовремя прекратить выполнение итераций.

### **§ 7.5. О некоторых подходах к решению задач локализации и отыскания решений систем нелинейных уравнений**

Подчеркнем еще раз, что одной из наиболее трудных проблем, возникающих при решении систем нелинейных уравнений, является задача локализации решения. Изложим некоторые подходы к ее решению, широко применяемые в практике вычислений. Указанные методы можно применять и для вычисления решения с заданной точностью  $\varepsilon$ .

**1. Использование методов минимизации.** Иногда бывает полезно свести задачу отыскания решения системы нелинейных уравнений к задаче отыскания минимума функции многих переменных. В простейшем варианте это сведение выглядит следующим образом. Введем функцию  $\Phi(\mathbf{x}) = \sum_{i=1}^m (f_i(\mathbf{x}))^2$ . Она неотрицательна и достигает своего минимума (равного нулю) тогда и только тогда, когда  $f_i(\mathbf{x}) = 0$  для всех  $i = 1, 2, \dots, m$ , т.е.  $\mathbf{x}$  является решением системы (7.1).

Применяя для отыскания минимума функции  $\Phi$  один из итерационных методов минимизации — методов спуска (см. гл. 10), можно найти вполне удовлетворительное приближение к решению  $\bar{\mathbf{x}}$ , которое затем имеет смысл использовать как начальное приближение  $\mathbf{x}^{(0)}$  в одном из итерационных методов решения нелинейных систем.

Выгода от указанного сведения исходной задачи к задаче минимизации состоит в том, что, как правило, методы спуска имеют более широкую область сходимости. Использование методов спуска можно рассматривать и как один из способов локализации решений системы (7.1). Применение на заключительном этапе методов, специально ори-

ентированных на решение нелинейных систем, вызвано тем, что вблизи искомого решения методы спуска сходятся медленнее.

Следует отметить, что функция  $\Phi(\mathbf{x})$  может иметь и ненулевые локальные минимумы, и в зависимости от выбора начального приближения методы спуска могут приводить к точкам локального минимума, не являющимися решениями системы (7.1).

**Пример 7.4.** Решения системы (7.4) являются точками глобального минимума функции

$$\Phi(x_1, x_2) = (x_1^3 + x_2^3 - 8x_1x_2)^2 + (x_1 \ln x_2 - x_2 \ln x_1)^2.$$

**2. Метод продолжения по параметру.** Сначала заметим, что довольно часто на практике встречаются ситуации, когда система нелинейных уравнений естественным образом зависит от некоторого параметра  $t$ , т.е. имеет вид

$$f(\mathbf{x}, t) = 0, \quad (7.24)$$

а решение ее следует найти при некотором фиксированном значении параметра, например при  $t = 1$ . В частности, этим свойством обладает система из примера 7.1. Предположим, что при каждом  $t \in [0, 1]$  система (7.24) имеет решение  $\bar{\mathbf{x}} = \bar{\mathbf{x}}(t)$ , непрерывно зависящее от параметра  $t$ , причем при  $t = 0$  решение системы  $f(\mathbf{x}, t) = 0$  известно либо легко вычисляется.

Таким образом, семейство решений  $\bar{\mathbf{x}}(t)$  описывает в пространстве  $R^m$  траекторию, начальная точка  $\bar{\mathbf{x}}(0)$  которой известна, а конечная  $\bar{\mathbf{x}}(1)$  подлежит определению (рис. 7.5).

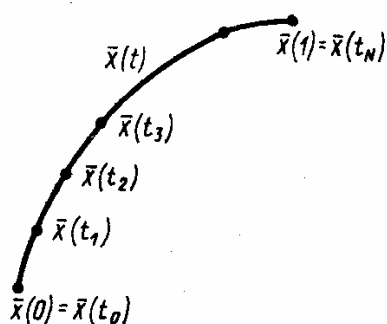


Рис. 7.5

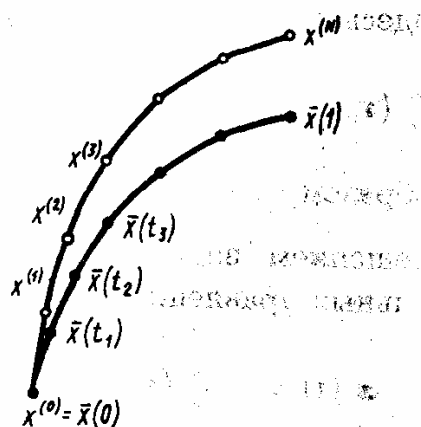


Рис. 7.6

И в тех случаях, когда система не зависит от параметра, можно ввести параметр  $t$  так, чтобы были выполнены указанные выше условия. Например, если  $\mathbf{x}^*$  — известное приближение к решению системы  $f(\mathbf{x}) = 0$ , то можно рассмотреть систему вида (7.24), полагая  $f(\mathbf{x}, t) = f(\mathbf{x}) - (1 - t)f(\mathbf{x}^*)$ .

Введем на отрезке  $[0, 1]$  набор точек  $0 = t_0 < t_1 < \dots < t_N = 1$ . Используя тот или иной итерационный метод, решим последовательно для  $k = 0, 1, 2, \dots, N$  системы  $f(\mathbf{x}, t_k) = 0$ . При этом за начальное приближение к  $\bar{\mathbf{x}}(t_k)$  будем принимать решение  $\bar{\mathbf{x}}(t_{k-1})$ . Если разность  $t_k - t_{k-1}$  достаточно мала, то можно ожидать, что  $\bar{\mathbf{x}}(t_{k-1})$  будет достаточно хорошим начальным приближением к  $\bar{\mathbf{x}}(t_k)$ , обеспечивающим сходимость используемого итерационного метода.

**З а м е ч а н и е.** Довольно часто на практике проводится исследование зависимости определенных характеристик объекта от некоторого параметра  $t$ . Для таких задач метод продолжения естествен. Более того, точки  $t_0, t_1, \dots, t_N$  можно выбрать, используя дополнительные соображения, причем решение  $\bar{\mathbf{x}}(t_k)$  представляет интерес не только для  $k = N$ , но и для всех  $k = 0, 1, \dots, N$ .

**3. Метод дифференцирования по параметру.** Предположим, что решение  $\bar{\mathbf{x}}(t)$  системы (7.24) является гладкой функцией параметра  $t$ . Дифференцируя тождество  $f(\bar{\mathbf{x}}(t), t) = 0$  по  $t$ , получим

$$f'_{\mathbf{x}}(\bar{\mathbf{x}}(t), t)\bar{\mathbf{x}}'(t) + f'_t(\bar{\mathbf{x}}(t), t) = 0.$$

Здесь  $f'_{\mathbf{x}}(\bar{\mathbf{x}}, t)$  — матрица с элементами  $\frac{\partial f_i}{\partial x_j}(\bar{\mathbf{x}}, t)$  ( $i, j = 1, 2, \dots, m$ ), а  $f'_t(\bar{\mathbf{x}}, t)$  — вектор-столбец с элементами  $\frac{\partial f_i}{\partial t}(\bar{\mathbf{x}}, t)$  ( $i = 1, 2, \dots, m$ ). Таким образом, если матрица  $f'_{\mathbf{x}}$  невырождена ( $\det f'_{\mathbf{x}} \neq 0$ ), то  $\bar{\mathbf{x}}(t)$  является решением задачи Коши для системы обыкновенных дифференциальных уравнений

$$\mathbf{x}'(t) = -(f'_{\mathbf{x}}(\mathbf{x}(t), t))^{-1}f'_t(\mathbf{x}(t), t), \quad \mathbf{x}(0) = \bar{\mathbf{x}}(0). \quad (7.25)$$

Интересующее нас значение решения  $\bar{\mathbf{x}}(1)$  можно теперь найти приближенно, применяя численные методы решения задачи Коши.

Например, метод Эйлера приводит к процессу

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - (t_{k+1} - t_k)(f'_x(\mathbf{x}^{(k)}, t_k))^{-1} f'_t(\mathbf{x}^{(k)}, t_k), \quad k = 0, 1, \dots, N-1,$$

где  $\mathbf{x}^{(0)} = \bar{\mathbf{x}}(0)$ ,  $\bar{\mathbf{x}}^{(k)}$  — приближение к  $\bar{\mathbf{x}}(t_k)$  (рис. 7.6). Конечно, метод Эйлера приведен здесь только для удобства иллюстрации, а в реальной ситуации используется один из методов более высокого порядка точности.

Полученное указанным способом значение  $\mathbf{x}^{(N)}$  можно использовать и как хорошее начальное приближение к  $\bar{\mathbf{x}}(1)$  в одном из итерационных методов решения системы (7.24).

**З а м е ч а н и е 1.** Иногда метод дифференцирования по параметру называют *методом Давиденко*.

**З а м е ч а н и е 2.** Методы продолжения и дифференцирования по параметру нередко позволяют успешно преодолевать непростую проблему локализации. Однако следует отметить, что эти методы далеко не всегда оказываются эффективными и их практическое применение требует определенной осторожности.

## § 7.6. Дополнительные замечания

1. Существенно более подробная и богатая информация о системах нелинейных уравнений и методах их решения содержится в книгах [61], [32]. Рекомендуем также обратиться к учебнику [9].

2. В последнее время значительный интерес проявляется к так называемым квазиньютоновским методам, которые получаются при специальных аппроксимациях матрицы Якоби. Часто такая аппроксимация сочетается с использованием гибридных алгоритмов подобно тому, как это делается для решения одного нелинейного уравнения (см. § 4.8). Полезные обсуждения таких методов можно найти в [32].

3. Иногда подходящим для решения задачи методом оказывается метод установления (см. [9]). Чаше это бывает тогда, когда решение системы (7.1) описывает устойчивое стационарное состояние некоторой физической системы.

4. Рекомендовать тот или иной метод как наиболее подходящий для решения системы нелинейных уравнений невозможно без тщательного изучения конкретной задачи.

## Глава 8

### МЕТОДЫ РЕШЕНИЯ ПРОБЛЕМЫ СОБСТВЕННЫХ ЗНАЧЕНИЙ

Вычисление собственных значений и собственных векторов — одна из тех сложных вычислительных задач, с которой часто приходится сталкиваться инженеру или научному работнику, занимающемуся конструированием или анализом больших технических систем. В электрических и механических системах собственные числа отвечают собственным частотам колебаний, а собственные векторы характеризуют соответствующие формы (моды) колебаний. Знание собственных чисел позволяет анализировать многие процессы, исследовать и управлять ими. Оценка величин критических нагрузок при расчете строительных конструкций также основана на информации о собственных значениях и собственных векторах матриц.

Собственные числа и собственные векторы являются важнейшими характеристиками, отражающими существенные стороны линейных моделей. Поэтому, конечно, дальнейшее расширение процесса математического моделирования приведет к тому, что владение методами решения проблемы собственных значений станет неотъемлемым элементом инженерного образования.

#### § 8.1. Постановка задачи.

##### Некоторые вспомогательные сведения

1. **Постановка задачи.** В данной главе мы ограничимся рассмотрением методов решения проблемы собственных значений только для квадратных матриц  $A$  порядка  $m$  с вещественными элементами  $a_{ij}$  ( $i, j = 1, 2, \dots, m$ ). Будем всюду под  $\|x\|$  понимать норму  $\|x\|_2$  и под  $(x, y)$  — скалярное произведение векторов  $x, y$  (см. § 5.2).

Напомним, что число  $\lambda$  называется *собственным значением* (собст-



венным числом) матрицы  $A$ , если существует ненулевой вектор  $x$ , удовлетворяющий уравнению

$$Ax = \lambda x \quad (8.1)$$

и называемый *собственным вектором* матрицы  $A$ , отвечающим собственному значению  $\lambda$ .

Запишем систему (8.1) в виде

$$(A - \lambda E)x = 0.$$

Эта однородная система имеет ненулевое решение  $x$  тогда и только тогда, когда определитель матрицы системы равен нулю, т.е.

$$\det(A - \lambda E) = 0. \quad (8.2)$$

Раскрытие этого уравнения приводит к так называемому *характеристическому* (или *вековому*) *уравнению*

$$\lambda^m + p_1 \lambda^{m-1} + p_2 \lambda^{m-2} + \dots + p_{m-1} \lambda + p_m = 0, \quad (8.3)$$

представляющему собой алгебраическое уравнение степени  $m$ .

Известно, что характеристическое уравнение имеет в области комплексных чисел ровно  $m$  корней  $\lambda_1, \lambda_2, \dots, \lambda_m$  (с учетом их кратности). Таким образом, каждая квадратная матрица  $A$  порядка  $m$  обладает набором из  $m$  собственных значений  $\lambda_1, \lambda_2, \dots, \lambda_m$ .

Если матрица  $A$  симметричная, то все ее собственные значения являются вещественными числами. Для несимметричных матриц возможно наличие комплексных собственных значений вида  $\lambda = \alpha + i\beta$  с ненулевой мнимой частью. В этом случае собственным значением матрицы обязательно является и комплексно-сопряженное число  $\bar{\lambda} = \alpha - i\beta$ .

В ряде задач механики, физики, химии, техники, биологии требуется получение всех собственных значений некоторых матриц, а иногда и всех собственных векторов. В такой постановке задачу называют *полной проблемой собственных значений*.

Довольно часто определению подлежат не все собственные значения и собственные векторы, а лишь небольшая их часть. Например, существенный интерес во многих приложениях представляют максимальное или минимальное по модулю собственное значение или же собственное значение, наиболее близко расположенное к заданному значению. Такие задачи являются примерами *частичных проблем собственных значений*.

Может показаться, что достаточно ограничиться только рассмотрением методов решения полной проблемы собственных значений, так

как все остальные проблемы являются ее частными случаями. Однако такой подход неоправдан, поскольку ориентирует на работу по получению значительного объема заведомо ненужной информации и требует существенно большего объема вычислений, чем это необходимо в действительности. Поэтому для решения различных частных проблем собственных значений разработан ряд специальных методов.

**Пример 8.1.** Найдём собственные числа матрицы

$$A = \begin{bmatrix} 2 & -9 & 5 \\ 1.2 & -5.3999 & 6 \\ 1 & -1 & -7.5 \end{bmatrix}. \quad (8.4)$$

Запишем характеристический многочлен

$$\begin{aligned} P_3(\lambda) &= \det(A - \lambda E) = \det \begin{bmatrix} 2-\lambda & -9 & 5 \\ 1.2 & -5.3999-\lambda & 6 \\ 1 & -1 & -7.5-\lambda \end{bmatrix} = \\ &= -\lambda^3 - 10.8999\lambda^2 - 26.49945\lambda - 21.002. \end{aligned}$$

Используя один из итерационных методов решения нелинейных уравнений (например, метод Ньютона), нетрудно определить один из корней уравнения  $P_3(\lambda) = 0$ , а именно  $\lambda_1 \approx -7.87279$ . Разделив  $P_3(\lambda)$  на  $\lambda - \lambda_1$ , имеем  $\frac{P_3(\lambda)}{\lambda + 7.87279} \approx P_2(\lambda) = \lambda^2 + 3.02711\lambda + 2.66765$ . Решая квадратное уравнение  $P_2(\lambda) = 0$ , находим корни  $\lambda_{2,3} \approx -1.51356 \pm 0.613841 i$ .

Таким образом, матрица  $A$  имеет одно вещественное собственное значение  $\lambda_1 \approx -7.87279$  и два комплексно-сопряженных собственных значения  $\lambda_{2,3} \approx -1.51356 \pm 0.613841 i$ .

Численные методы решения проблемы собственных значений, использовавшиеся до конца 40-х годов, сводились в конечном счете к решению характеристического уравнения (8.3). Этой классической схеме следовали и мы в примере 8.1. При реализации такого подхода основные усилия были направлены на разработку эффективных методов быстрого вычисления коэффициентов характеристического уравнения: Методы такого класса получили названия *прямых*; к ним относятся пользовавшиеся популярностью методы Крылова<sup>1</sup>, Данилевского, Леверье и др.

---

<sup>1</sup> Алексей Николаевич Крылов (1863 — 1945) — русский математик, механик и кораблестроитель, является автором первого в мировой научной литературе курса по численным методам — изданных в 1911 г. "Лекций о приближенных вычислениях".

Однако указанный подход становится неудовлетворительным, если речь идет о вычислении собственных значений матриц, имеющих порядок  $m$  в несколько десятков (и тем более сотен), т.е. матриц довольно скромных по современным понятиям размеров.

Одна из причин состоит в том, что хотя задачи (8.1) и (8.3) формально эквивалентны, они имеют разную обусловленность. Так как корни многочлена  $P_m(x)$  высокой степени чрезвычайно чувствительны к погрешностям в коэффициентах, то на этапе вычисления коэффициентов характеристического уравнения может быть в значительной степени потеряна информация о собственных значениях матрицы.

С появлением ЭВМ широкое распространение получили итерационные методы решения проблемы собственных значений, не использующие вычисление характеристического многочлена. К началу 60-х годов эти методы практически полностью вытеснили прямые методы из практики вычислений.

**2. Преобразование подобия.** Говорят, что матрицы  $A$  и  $B$  подобны, если существует невырожденная матрица  $P$  (*матрица подобия*) такая, что  $B = P^{-1}AP$ . Само преобразование матрицы  $A$  к виду  $B = P^{-1}AP$  называется *преобразованием подобия*. Преобразование подобия матрицы возникает естественным образом как результат замены переменных (или перехода к новому базису) в пространстве  $m$ -мерных векторов. Действительно, пусть  $y$  — результат применения матрицы  $A$  к вектору  $x$ , т.е.  $y = Ax$ . Произведем замену переменных  $x = Px'$ ,  $y = Py'$ . Тогда равенство  $y = Ax$  примет вид  $y' = P^{-1}APx'$ . Это означает, что в новых переменных то же самое преобразование осуществляется уже не матрицей  $A$ , а матрицей  $P^{-1}AP$ , подобной  $A$ .

Важно то, что и полученная в результате преобразования подобия матрица имеет тот же набор собственных чисел. В самом деле, рассмотрим характеристический многочлен для матрицы  $P^{-1}AP$  и воспользуемся тем, что определитель произведения квадратных матриц равен произведению соответствующих определителей:

$$\begin{aligned} \det(P^{-1}AP - \lambda E) &= \det(P^{-1}(A - \lambda E)P) = \\ &= \det P^{-1} \det(A - \lambda E) \det P = \det(A - \lambda E). \end{aligned}$$

Таким образом, характеристические многочлены, а следовательно, и собственные числа матриц  $A$  и  $P^{-1}AP$  совпадают. Соответствующие собственные векторы  $x$  и  $x'$  не совпадают, но, как нетрудно установить, они связаны равенством  $x = Px'$ .

Если бы матрицу  $A$  с помощью преобразования подобия или последовательности таких преобразований удалось привести к верхнему треугольному виду, то проблему вычисления собственных значений

можно было бы считать решенной. Дело в том, что у верхней треугольной матрицы

$$B = \begin{bmatrix} b_{11} & b_{12} & \dots & b_{1m} \\ 0 & b_{22} & \dots & b_{2m} \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & b_{mm} \end{bmatrix} \quad (8.5)$$

собственными числами являются элементы главной диагонали  $b_{ii}$ . В этом нетрудно убедиться, если записать характеристический многочлен:  $\det(B - \lambda E) = (b_{11} - \lambda)(b_{22} - \lambda) \dots (b_{mm} - \lambda)$ .

Оказывается, что преобразованием подобия матрицу  $A$  можно привести к еще более простому виду, чем (8.5). Справедлива (см. [23]) следующая теорема.

**Т е о р е м а 8.1.** Любую квадратную матрицу  $A$  с помощью преобразования подобия можно привести к следующему виду:

$$P^{-1}AP = \Lambda = \begin{bmatrix} \lambda_1 & \sigma_1 & 0 & 0 & \dots & 0 & 0 \\ 0 & \lambda_2 & \sigma_2 & 0 & \dots & 0 & 0 \\ 0 & 0 & \lambda_3 & \sigma_3 & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \dots & \lambda_{m-1} & \sigma_{m-1} \\ 0 & 0 & 0 & 0 & \dots & 0 & \lambda_m \end{bmatrix}. \quad (8.6)$$

Здесь  $\lambda_1, \lambda_2, \dots, \lambda_m$  — собственные числа матрицы  $A$ . Числа  $\sigma_i$  принимают одно из двух значений 0 или 1, причем если  $\sigma_i = 1$ , то обязательно  $\lambda_i = \lambda_{i+1}$ .

Матрица (8.6) называется *жордановой формой матрицы  $A$* .

**3. Матрицы простой структуры.** В этой главе особое внимание будет уделено *матрицам простой структуры*, т.е. матрицам, которые с помощью преобразования подобия можно привести к диагональному виду:

$$P^{-1}AP = D = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \lambda_m \end{bmatrix}. \quad (8.7)$$

Запишем равенство (8.7) в виде  $AP = DP$  и заметим, что оно верно тогда и только тогда, когда каждый  $j$ -й столбец матрицы  $P$  является собственным вектором матрицы  $A$ , отвечающим собственному значению  $\lambda_j$ . Таким образом, верна следующая теорема.

**Теорема 8.2.** Матрица  $A$  является матрицей простой структуры тогда и только тогда, когда она имеет  $m$  линейно независимых собственных векторов  $e_1, e_2, \dots, e_m$ , отвечающих собственным значениям  $\lambda_1, \lambda_2, \dots, \lambda_m$  соответственно.

Указанные в теореме собственные векторы  $e_1, e_2, \dots, e_m$  образуют базис в пространстве  $m$ -мерных векторов. Поэтому каждый  $m$ -мерный вектор  $x$  может быть однозначно представлен в виде линейной комбинации этих векторов:

$$x = c_1 e_1 + c_2 e_2 + \dots + c_m e_m. \quad (8.8)$$

Какие же матрицы заведомо могут быть приведены к диагональному виду? Следующие два предложения частично отвечают на этот вопрос.

**Теорема 8.3.** Если все собственные значения матрицы  $A$  различны, то она является матрицей простой структуры.

**Теорема 8.4.** Если  $A$  — вещественная симметричная матрица, то она подобна диагональной матрице, причем матрица подобия  $P$  может быть выбрана ортогональной (т.е. удовлетворяющей условию  $P^{-1} = P^T$ ).

**4. Локализация собственных значений.** С помощью так называемых теорем локализации иногда удается получить грубые оценки расположения собственных чисел. Изложим самый известный из этих результатов — теорему Гершгорина<sup>1</sup>.

Пусть  $r_i = \sum_{\substack{j=1 \\ j \neq i}}^m |a_{ij}|$  — сумма модулей внедиагональных элементов  $i$ -й

строки матрицы  $A$ . Обозначим через  $S_i$  круг радиуса  $r_i$  на комплексной плоскости с центром в точке  $a_{ii}$ , т.е.  $S_i = \{z \in \mathbb{C} : |z - a_{ii}| \leq r_i\}$ . Будем называть круги  $S_i$  *кругами Гершгорина*. Имеет место следующее утверждение.

**Теорема 8.5 (теорема Гершгорина).** Все собственные значения матрицы  $A$  лежат в объединении кругов  $S_1, S_2, \dots, S_m$ .

□ Возьмем произвольное собственное значение  $\lambda$  матрицы  $A$  и соответствующий собственный вектор  $x$ . Пусть  $x_i$  — максимальная по модулю координата вектора  $x$ . Запишем  $i$ -е уравнение системы (8.1) в следующем виде:

$$(a_{ii} - \lambda) x_i = - \sum_{j \neq i} a_{ij} x_j.$$

---

<sup>1</sup> Семен Аронович Гершгорин (1901 — 1933) — российский математик. Результат, о котором идет речь, был опубликован им в 1931 г.

Из этого равенства с учетом оценки  $|x_j/x_i| \leq 1$  следует неравенство

$$|a_{ii} - \lambda| \leq \sum_{j \neq i} |a_{ij}| \left| \frac{x_j}{x_i} \right| \leq r_i.$$

Таким образом,  $\lambda \in S_i$ . ■

**Пример 8.2.** Для матрицы

$$A = \begin{bmatrix} -2 & 0.5 & 0.5 \\ -0.5 & -3.5 & 1.5 \\ 0.8 & -0.5 & 0.5 \end{bmatrix}$$

круги Гершгорина изображены на рис. 8.1. Здесь  $r_1 = 1$ ,  $r_2 = 2$ ,  $r_3 = 1.3$ .

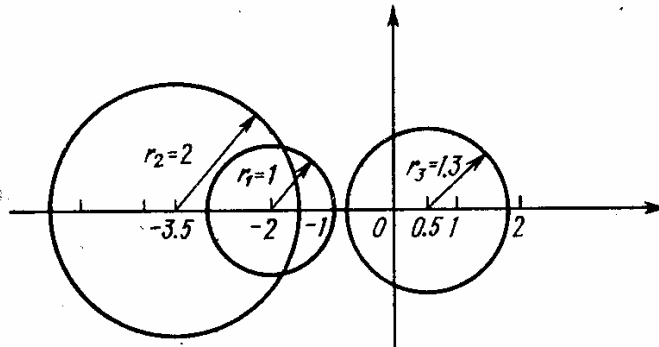


Рис. 8.1

Следующий результат является полезным дополнением к теореме Гершгорина.

**Теорема 8.6.** Если  $k$  кругов Гершгорина образуют замкнутую область  $\bar{G}$ , изолированную от других кругов, то в  $\bar{G}$  находится ровно  $k$  собственных значений матрицы  $A$  (с учетом их кратности).

**С л е д с т в и е.** Если какой-либо круг Гершгорина изолирован, то он содержит ровно одно собственное значение матрицы  $A$ .

**Пример 8.3.** Для матрицы  $A$  из примера 8.2 в объединении кругов  $S_1$  и  $S_2$  находится ровно два собственных значения  $\lambda_1$  и  $\lambda_2$ , а круг  $S_3$  содержит ровно одно собственное значение  $\lambda_3$ .

**5. Отношение Рэлея.** При вычислении собственных чисел и собственных векторов симметричных матриц важную роль играет функция

$$\rho(\mathbf{x}) = \frac{(\mathbf{Ax}, \mathbf{x})}{(\mathbf{x}, \mathbf{x})}, \quad (8.9)$$

называемая *отношением Рэля*<sup>1</sup>. Следующее предложение частично объясняет значение этой величины.

**Теорема 8.7.** Пусть  $A$  — симметричная матрица. Тогда справедливы следующие утверждения:

1<sup>0</sup>) минимальное и максимальное собственные значения матрицы  $A$  вычисляются по формулам

$$\lambda_{\min} = \min_{\mathbf{x} \neq 0} \rho(\mathbf{x}), \quad \lambda_{\max} = \max_{\mathbf{x} \neq 0} \rho(\mathbf{x});$$

2<sup>0</sup>) вектор  $\mathbf{x}$  является стационарной точкой функции  $\rho(\mathbf{x})$  (т.е. удовлетворяет условию  $\text{grad } \rho(\mathbf{x}) = 0$ ) тогда и только тогда, когда  $\mathbf{x}$  — собственный вектор матрицы  $A$ .

При построении методов решения проблемы собственных значений существенно используется то обстоятельство, что если  $\mathbf{x}$  — хорошее приближение к собственному вектору  $\mathbf{e}_j$ , то  $\rho(\mathbf{x})$  — хорошее приближение к собственному числу  $\lambda_j$ .

**6. Обусловленность задачи вычисления собственных значений и собственных векторов.** Пусть  $A_*$  — матрица с приближенно заданными элементами  $a_{ij}^* \approx a_{ij}$ . Обозначим через  $\lambda_j^*$  ( $j = 1, 2, \dots, m$ ) собственные числа матрицы  $A_*$ . Рассмотрение вопроса о том, как влияет погрешность задания матрицы на погрешность искомым собственным значениям, начнем с формулировки следующего известного результата.

**Теорема 8.8.** Пусть  $A$  и  $A_*$  — симметричные матрицы, а  $\lambda_j$  и  $\lambda_j^*$  — их собственные числа, упорядоченные по возрастанию. Тогда справедливы оценки погрешности

$$\max_{1 \leq j \leq m} |\lambda_j - \lambda_j^*| \leq \|A - A_*\|_2, \quad (8.10)$$

$$\left[ \sum_{j=1}^m (\lambda_j - \lambda_j^*)^2 \right]^{\frac{1}{2}} \leq \|A - A_*\|_F. \quad (8.11)$$

Теорема 8.8 означает, что задача вычисления собственных значений симметричных матриц очень хорошо обусловлена. Следовательно, в

---

<sup>1</sup> Джон Уильям Рэлей (1842 — 1919) — английский физик и математик.

этом случае собственные числа надежно определяются заданием элементов матрицы. К сожалению, для несимметричных матриц дело обстоит совсем иначе. Хотя задача вычисления собственных значений и в этом случае является устойчивой, для многих несимметричных матриц собственные значения чрезвычайно чувствительны к погрешностям задания коэффициентов.

**Пример 8.4.** Приведем принадлежащий Дж.Х.Уилкинсону [83] пример матрицы, очень плохо обусловленной по отношению к проблеме собственных значений.

Собственными числами верхней треугольной матрицы 20-го порядка

$$A = \begin{bmatrix} 20 & 20 & 0 & 0 & \dots & 0 & 0 \\ 0 & 19 & 20 & 0 & \dots & 0 & 0 \\ 0 & 0 & 18 & 20 & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \dots & 2 & 20 \\ 0 & 0 & 0 & 0 & \dots & 0 & 1 \end{bmatrix}$$

являются числа  $\lambda_1 = 1, \lambda_2 = 2, \dots, \lambda_{20} = 20$ . Заметим, что для этой матрицы характеристический многочлен  $P_{20}(\lambda) = (20 - \lambda)(19 - \lambda)\dots(1 - \lambda)$  только лишь знаком отличается от многочлена, рассмотренного в примере 3.8 в связи с плохой обусловленностью его корней. Добавим малое  $\epsilon$  к элементу  $a_{20,1} = 0$ . В результате характеристическое уравнение примет вид

$$(20 - \lambda)(19 - \lambda) \dots (1 - \lambda) = 20^{19}\epsilon.$$

При  $\epsilon = 10^{-10}$  собственные значения возмущенной матрицы таковы:  $\lambda_1^* \approx 0.996$ ,  $\lambda_2^* \approx 2.11$ ,  $\lambda_3^* \approx 2.57$ ,  $\lambda_{4,5}^* \approx 3.97 \pm 1.09 i$ ,  $\lambda_{6,7}^* \approx 5.89 \pm 1.95 i$ ,  $\lambda_{8,9}^* \approx 8.12 \pm 2.53 i$ ,  $\lambda_{10,11}^* \approx 10.5 \pm 2.73 i$ ,  $\lambda_{12,13}^* \approx 12.9 \pm 2.53 i$ ,  $\lambda_{14,15}^* \approx 15.1 \pm 1.95 i$ ,  $\lambda_{16,17}^* \approx 17.0 \pm 1.09 i$ ,  $\lambda_{18}^* \approx 18.4$ ,  $\lambda_{19}^* \approx 18.9$ ,  $\lambda_{20}^* \approx 20.0$ . Как нетрудно видеть, большинство значений оказались полностью искаженными.

Отметим, что число обусловленности  $\text{cond}(A)$  матрицы  $A$  не характеризует обусловленность матрицы по отношению к проблеме собственных значений. Оказывается, что такой характеристикой чувствительности собственных значений относительно погрешности задания матрицы для матрицы простой структуры служит число обусловленности матрицы  $P$ , столбцы которой являются собственными векторами матрицы  $A$ . В подтверждение сказанного приведем следующий результат.

**Теорема 8.9.** Пусть  $P^{-1}AP = D$ , где  $D$  — диагональная матрица



из собственных значений матрицы  $A$ , и пусть  $d = \text{cond}_2(P)\|A - A_*\|$ . Тогда каждое собственное значение матрицы  $A_*$  удалено от некоторого собственного значения матрицы  $A$  не более чем на  $d$ .

Пусть  $x$  — собственный вектор матрицы  $A$ , отвечающий собственному значению  $\lambda$ , а  $x^*$  — собственный вектор приближенно заданной матрицы  $A_*$ , отвечающий собственному значению  $\lambda^*$ . Прежде чем обсуждать обусловленность задачи вычисления собственного вектора  $x$ , заметим, что здесь вопрос о выборе меры близости векторов  $x^*$  и  $x$  не является тривиальным. Выбор в качестве такой меры величины  $\|x - x^*\|$  неудачен. Дело в том, что собственные векторы  $x^*$  и  $x$  не определяются однозначно. Во всяком случае после умножения каждого из них на любые числа  $\alpha_1 \neq 0$  и  $\alpha_2 \neq 0$  полученные векторы  $\alpha_1 x^*$  и  $\alpha_2 x$  снова являются собственными. Поэтому имеет смысл стремиться не к тому, чтобы векторы  $x^*$  и  $x$  были близки по норме, а к тому, чтобы они были близки по направлению. Исходя из этого, примем в качестве меры близости  $x^*$  к  $x$  величину  $|\sin \varphi|$ , где  $\varphi$  — угол между векторами  $x^*$  и  $x$ , вычисляемый по формуле

$$\varphi = \arccos \left[ \frac{(x^*, x)}{\|x^*\| \|x\|} \right].$$

Задача вычисления собственных векторов симметричной матрицы хорошо обусловлена, если собственные значения хорошо отделены друг от друга. В подтверждение сказанного приведем следующий результат.

**Теорема 8.10.** Пусть  $A$  и  $A_*$  — симметричные матрицы. Тогда верна оценка

$$|\sin \varphi| \leq \frac{\|A - A_*\|_2}{\gamma}.$$

Здесь  $\varphi$  — угол между векторами  $x^*$  и  $x$ , а  $\gamma$  — расстояние от  $\lambda^*$  до ближайшего из несовпадающих с  $\lambda$  собственных значений матрицы  $A$ .

В случае, когда матрица  $A$  несимметрична, собственные векторы могут оказаться очень плохо обусловленными.

**З а м е ч а н и е.** Подавляющее большинство встречающихся на практике матриц являются матрицами простой структуры. Это обстоятельство, а также большая простота анализа методов вычислений и формулировок соответствующих результатов позволяют

нам в основном остановиться на проблеме собственных значений для матриц простой структуры.

## § 8.2. Степенной метод

Пусть требуется вычислить максимальное по модулю собственное значение  $\lambda_1$  матрицы  $A$ , причем известно, что

$$|\lambda_1| > |\lambda_2| \geq |\lambda_3| \geq \dots \geq |\lambda_m|. \quad (8.12)$$

**З а м е ч а н и е.** Собственное значение  $\lambda_1$  в данном случае должно быть вещественным, поскольку в противном случае собственным значением было бы также равное ему по модулю число  $\bar{\lambda}_1$ .

**1. Степенной метод без сдвигов.** Опишем простейший вариант степенного метода, применяемого для вычисления  $\lambda_1$ . Возьмем произвольный начальный вектор  $\mathbf{x}^{(0)}$  и построим последовательности векторов  $\{\mathbf{x}^{(k)}\}_{k=0}^{\infty}$  и приближений  $\{\lambda_1^{(k)}\}_{k=0}^{\infty}$  к  $\lambda_1$ , используя формулы

$$\mathbf{x}^{(k)} = A\mathbf{x}^{(k-1)} \quad (8.13)$$

$$\lambda_1^{(k)} = \frac{(\mathbf{x}^{(k)}, \mathbf{x}^{(k-1)})}{(\mathbf{x}^{(k-1)}, \mathbf{x}^{(k-1)})}. \quad (8.14)$$

**З а м е ч а н и е.** Правая часть формулы (8.14) — это просто отношение Рэля, вычисленное при  $\mathbf{x} = \mathbf{x}^{(k-1)}$ . В самом деле,  $\lambda_1^{(k)} = (A\mathbf{x}^{(k-1)}, \mathbf{x}^{(k-1)})/(\mathbf{x}^{(k-1)}, \mathbf{x}^{(k-1)}) = \rho(\mathbf{x}^{(k-1)})$ .

Справедлива следующая теорема.

**Т е о р е м а 8.11.** Пусть  $A$  — матрица простой структуры, для которой выполнено условие (8.12). Предположим, что в разложении

$$\mathbf{x}^{(0)} = c_1 \mathbf{e}_1 + c_2 \mathbf{e}_2 + \dots + c_m \mathbf{e}_m \quad (8.15)$$

по базису из собственных векторов коэффициент  $c_1$  не равен нулю. Тогда  $\lambda_1^{(k)} \rightarrow \lambda_1$  при  $k \rightarrow \infty$  и верна оценка относительной погрешности

$$\delta(\lambda_1^{(k)}) = \frac{|\lambda_1^{(k)} - \lambda_1|}{|\lambda_1|} \leq C \left| \frac{\lambda_2}{\lambda_1} \right|^k. \quad (8.16)$$

□ Как легко установить, вектор  $\mathbf{x}^{(k)}$  удовлетворяет равенству  $\mathbf{x}^{(k)} = A^k \mathbf{x}^{(0)}$ , т.е. получается из  $\mathbf{x}^{(0)}$  умножением на  $k$ -ю степень матрицы  $A$  (отсюда и название метода). Так как  $A\mathbf{e}_i = \lambda_i \mathbf{e}_i$ , то  $A^k \mathbf{e}_i = \lambda_i^k \mathbf{e}_i$  и, следовательно,

$$\mathbf{x}^{(k)} = A^k \mathbf{x}^{(0)} = \lambda_1^k c_1 \mathbf{e}_1 + \lambda_2^k c_2 \mathbf{e}_2 + \dots + \lambda_m^k c_m \mathbf{e}_m \quad (8.17)$$

Положим  $\mathbf{z}^{(k)} = \frac{\mathbf{x}^{(k)}}{\lambda_1^k}$  и заметим, что  $\mathbf{z}^{(k)} \rightarrow c_1 \mathbf{e}_1$  при  $k \rightarrow \infty$ , причем

$$\mathbf{w}^{(k)} = \mathbf{z}^{(k)} - c_1 \mathbf{e}_1 = \left| \frac{\lambda_2}{\lambda_1} \right|^k c_2 \mathbf{e}_2 + \dots + \left| \frac{\lambda_m}{\lambda_1} \right|^k c_m \mathbf{e}_m$$

Так как  $\left| \frac{\lambda_i}{\lambda_1} \right| \leq \left| \frac{\lambda_2}{\lambda_1} \right|$  для всех  $i \geq 2$ , то

$$\|\mathbf{w}^{(k)}\| \leq c \left| \frac{\lambda_2}{\lambda_1} \right|^k. \quad (8.18)$$

Теперь нетрудно установить, что

$$\lambda_1^{(k)} = \lambda_1 \frac{(\mathbf{z}^{(k)}, \mathbf{z}^{(k-1)})}{(\mathbf{z}^{(k-1)}, \mathbf{z}^{(k-1)})} \rightarrow \lambda_1 \frac{(c_1 \mathbf{e}_1, c_1 \mathbf{e}_1)}{(c_1 \mathbf{e}_1, c_1 \mathbf{e}_1)} = \lambda_1$$

при  $k \rightarrow \infty$ . Более того,

$$\frac{|\lambda_1^{(k)} - \lambda_1|}{|\lambda_1|} = \frac{(\mathbf{z}^{(k)} - \mathbf{z}^{(k-1)}, \mathbf{z}^{(k-1)})}{(\mathbf{z}^{(k-1)}, \mathbf{z}^{(k-1)})} = \frac{(\mathbf{w}^{(k)} - \mathbf{w}^{(k-1)}, \mathbf{z}^{(k-1)})}{(\mathbf{z}^{(k-1)}, \mathbf{z}^{(k-1)})}. \quad (8.19)$$

Используя неравенство Коши—Буняковского  $|(x, y)| \leq \|x\| \cdot \|y\|$ , имеем

$$|(\mathbf{w}^{(k)} - \mathbf{w}^{(k-1)}, \mathbf{z}^{(k-1)})| \leq \|\mathbf{w}^{(k)} - \mathbf{w}^{(k-1)}\| \|\mathbf{z}^{(k-1)}\|. \quad (8.20)$$

Из равенства (8.19) и оценок (8.18), (8.20) следует, что

$$\delta(\lambda_1^{(k)}) \leq \frac{\|\mathbf{w}^{(k)} - \mathbf{w}^{(k-1)}\|}{\|\mathbf{z}^{(k-1)}\|} \leq \frac{\|\mathbf{w}^{(k)}\| + \|\mathbf{w}^{(k-1)}\|}{\|\mathbf{z}^{(k-1)}\|} \leq C_0 \left| \frac{\lambda_2}{\lambda_1} \right|^k. \blacksquare$$

**З а м е ч а н и е 1.** В действительности теорема 8.11 справедлива для произвольных матриц, удовлетворяющих условию (8.12). Предположение о том, что матрица  $A$  — простой структуры, потребовалось лишь для упрощения доказательства.

**З а м е ч а н и е 2.** Если  $|\lambda_1| > 1$ , то  $\|x^{(k)}\| \rightarrow \infty$  при  $k \rightarrow \infty$  (см. формулу (8.17)) и при вычислении на ЭВМ возможно переполнение. Если же  $|\lambda_1| < 1$ , то  $\|x^{(k)}\| \rightarrow 0$  и возможно исчезновение порядка. Для предупреждения этих ситуаций обычно вектор  $x^{(k)}$  нормируют, например, так, чтобы  $\|x^{(k)}\| = 1$  для всех  $k \geq 1$ . Одна из используемых модификаций такова:

$$y^{(k)} = Ax^{(k-1)}, \lambda^{(k)} = (y^{(k)}, x^{(k-1)}), x^{(k)} = \frac{y^{(k)}}{\|y^{(k)}\|}. \quad (8.21)$$

Предполагается, что  $\|x^{(0)}\| = 1$ .

Теорема 8.11 для метода (8.21) остается справедливой. Более того, последовательность  $x^{(k)}$  сходится к собственному вектору по направлению, т.е.  $\sin \varphi^{(k)} \rightarrow 0$  при  $k \rightarrow \infty$ , где  $\varphi^{(k)}$  — угол между векторами  $x^{(k)}$  и  $e_1$ .

**З а м е ч а н и е 3.** Крайне маловероятно, чтобы в разложении (8.15) вектора  $x^{(0)}$  по собственным векторам коэффициент  $c_1$  при  $e_1$  оказался равным нулю. Теоретически в этой исключительной ситуации метод не должен давать сходящуюся к  $\lambda_1$  последовательность. Однако при вычислении на ЭВМ по формулам (8.12) через несколько итераций вследствие погрешностей округления почти наверняка появится ненулевой коэффициент при  $e_1$  в разложении вектора  $x^{(k)}$ . Итерационный процесс снова окажется сходящимся (правда, потребуется выполнить большее число итераций).

**2. Апостериорная оценка погрешности.** В общем случае для решения проблемы собственных значений не существует эффективных апостериорных оценок погрешности, в особенности для собственных векторов. Более простой эта проблема выглядит для симметричных матриц.

Для оценки погрешности приближения  $\lambda^*$  к собственному значению  $\lambda$  симметричной матрицы полезно использовать следующую теорему.

**Т е о р е м а 8.12.** Пусть  $\lambda^*$  — произвольное число, а  $x^*$  — произвольный ненулевой вектор. Тогда для любой симметричной матрицы  $A$  существует собственное значение этой матрицы  $\lambda$  такое, что справедлива оценка

$$|\lambda - \lambda^*| \leq \frac{\|Ax^* - \lambda^*x^*\|}{\|x^*\|}. \quad (8.22)$$

Если  $x^*$  — приближенно вычисленный собственный вектор, то неравенство (8.22) позволяет дать простую апостериорную оценку погрешности вычисленного собственного значения  $\lambda^*$ . В частности, для степенного метода (8.13), (8.14) из (8.22) следует такая апостериорная оценка:

$$|\lambda_1 - \lambda_1^{(k)}| \leq \frac{\|x^{(k)} - \lambda_1^{(k)} x^{(k-1)}\|}{\|x^{(k-1)}\|}$$

(напомним, что здесь предполагается симметричность матрицы  $A$ ).

Пусть  $x^*$  — ненулевой вектор, рассматриваемый как приближение к собственному вектору  $x$ , который отвечает собственному значению  $\lambda$ . Далее, пусть  $\rho^* = \rho(x^*)$  — отношение Рэлея,  $r = Ax^* - \rho^*x^*$  — вектор невязки,  $\sigma = \frac{\|r\|}{\|x^*\|}$ . Если собственное значение  $\lambda$  хорошо отделено от остальных собственных значений матрицы  $A$ , то для оценки погрешности может быть использован следующий результат.

**Теорема 8.13.** Пусть  $\lambda$  — ближайшее к  $\rho^*$  собственное значение симметричной матрицы  $A$ ,  $x$  — соответствующий собственный вектор и  $\varphi$  — угол между векторами  $x^*$  и  $x$ . Тогда справедливы оценки

$$|\sin \varphi| \leq \frac{\sigma}{\gamma}, \quad |\lambda - \rho^*| \leq \frac{\sigma^2}{\gamma}.$$

Здесь  $\gamma = \min_{\lambda_i \neq \lambda} |\lambda_i - \rho^*|$  — расстояние от  $\rho^*$  до ближайшего из отличных от  $\lambda$  собственных значений матрицы  $A$ .

Приведем еще одно важное свойство симметричных матриц.

**Теорема 8.14.** Пусть  $A$  — симметричная матрица,  $x^*$  — произвольный ненулевой вектор,  $\rho^* = \rho(x^*)$ . Тогда  $\rho^*$  и  $x^*$  являются точными собственными числом и собственным вектором некоторой матрицы  $A_*$ , для которой

$$\|A - A_*\|_2 = \sigma. \quad (8.23)$$

Оценка (8.23) может оказаться очень полезной для обратного анализа ошибок (о существовании такого подхода к анализу ошибок мы говорили в § 3.6). Например, очень часто матрица  $A$ , для которой на ЭВМ производится вычисление собственных значений, является лишь приб-

лиженным представлением "истинной" матрицы  $\tilde{A}$ , собственными значениями и векторами которой в действительности и интересуется исследователь. Пусть известен порядок погрешности  $\varepsilon = \|A - \tilde{A}\|_2$  приближенно заданной матрицы и для найденной пары  $x^*$ ,  $\rho^* = \rho(x^*)$  величина  $\sigma = \frac{\|Ax^* - \rho^*x^*\|}{\|x^*\|}$  оказывается сравнимой с величиной  $\varepsilon$  или даже существенно меньше ее. В такой ситуации  $\rho^*$  и  $x^*$  оказываются собственными значением и вектором матрицы  $A_*$ , которая отличается от "истинной" матрицы почти так же, как отличается от нее матрица  $A$ . Вряд ли тогда следует стремиться к получению "более точных" решений.

**Пример 8.5.** Используя степенной метод, найдем для матрицы (8.5) максимальное по модулю собственное значение  $\lambda_1$ , а также отвечающий ему собственный вектор.

Возьмем  $x^{(0)} = (1, 0, 0)^T$  и будем вести вычисления по формулам (8.21).

**И т е р а ц и я.** Вычисляем  $y_1^{(1)} = 2x_1^{(0)} - 9x_2^{(0)} + 5x_3^{(0)} = 2$ ,  $y_2^{(1)} = 1.2x_1^{(0)} - 5.3999x_2^{(0)} + 6x_3^{(0)} = 1.2$ ,  $y_3^{(1)} = x_1^{(0)} - x_2^{(0)} - 7.5x_3^{(0)} = 1$ . Тогда  $\lambda_1^{(1)} = (y^{(1)}, x^{(0)}) = y_1^{(1)}x_1^{(0)} + y_2^{(1)}x_2^{(0)} + y_3^{(1)}x_3^{(0)} = 2 \cdot 1 + 1.2 \cdot 0 + 1 \cdot 0 = 2$ .

Далее,  $\|y^{(1)}\| = \sqrt{2^2 + 1.2^2 + 1^2} \approx 2.53772$  и  $x^{(1)} = \frac{y^{(1)}}{\|y^{(1)}\|} \approx (0.788110, 0.472866, 0.394055)^T$ .

Результаты десяти первых итераций с шестью знаками мантиссы приведены в табл. 8.1.

Т а б л и ц а 8.1

Номер итера- ции $k$	$\lambda_1^{(k)}$	$x_1^{(k)}$	$x_2^{(k)}$	$x_3^{(k)}$
0	-	1.000000	0.000000	0.000000
1	2.00000	0.788110	0.472866	0.394055
2	-1.24159	-0.250056	0.266743	-0.930763
3	-6.08121	-0.611733	-0.593143	0.523415
4	-9.50971	0.700557	0.583736	-0.410455
5	-8.23499	-0.716752	-0.579514	0.387853
6	-7.94591	0.720030	0.578443	-0.383353

Номер итера- ции $k$	$\lambda_1^{(k)}$	$x_1^{(k)}$	$x_2^{(k)}$	$x_3^{(k)}$
7	-7.88567	-0.720635	-0.578216	0.382446
8	-7.87462	0.720729	0.578174	-0.382446
9	-7.87294	-0.720739	-0.578167	0.382437
10	-7.87277	-0.720739	0.578167	-0.382437

Хотя мы не имеем в данном случае обоснованного критерия окончания, по-видимому, при  $k = 10$  следует прекратить вычисления и, округляя результаты, положить  $\lambda_1 \approx -7.873$ ,  $\mathbf{e}_1 \approx (-0.7207, 0.5782, -0.3824)^T$ .

Важными достоинствами степенного метода являются его простота, возможность эффективного использования разреженности матрицы и отсутствие необходимости преобразования матрицы  $A$ .

Недостаток метода в применении к многим прикладным задачам — довольно медленная сходимость. Часто в приложениях значение  $|\lambda_2|$  оказывается близким к  $|\lambda_1|$ . Так как скорость сходимости степенного метода определяется величиной  $|\frac{\lambda_2}{\lambda_1}| \approx 1$ , то в этом случае сходимость будем очень медленной.

**3. Степенной метод со сдвигами.** Существует несколько способов преодоления указанной трудности. Один из них заключается в применении степенного метода не к матрице  $A$ , а к матрице  $\tilde{A} = A - \sigma E$ , где  $\sigma$  — некоторое число. Собственными значениями матрицы  $A$  являются числа  $\lambda_i - \sigma$ , получаемые сдвигом собственных значений  $\lambda_i$  на число  $\sigma$ . Если число  $\lambda_1 - \sigma$  по-прежнему остается максимальным по модулю, то следует попытаться подобрать  $\sigma$  так, чтобы сделать величину  $\max_{2 \leq i \leq n} \frac{|\lambda_i - \sigma|}{|\lambda_1 - \sigma|}$  минимальной. Если, например, все собственные значения положительны, то такой минимум достигается при  $\sigma = (\lambda_2 + \lambda_n)/2$ .

После того как приближение  $\lambda_1^*$  к собственному значению вычислено, степенной метод можно использовать для вычисления очередного собственного значения. Один из приемов такого использования состоит в сдвиге собственных значений на  $\sigma = \lambda_1^*$ . В этом случае число

$\lambda_1 - \lambda_1^*$  станет минимальным по модулю, а максимальным по модулю окажется сдвиг другого собственного значения.

Существует несколько способов избавления от уже вычисленных собственных чисел и соответствующих собственных векторов с целью избежать их повторного вычисления. Эти способы принято называть *исчерпывающими*. Более подробную информацию о них можно найти, например, в [19], [62].

### § 8.3. Метод обратных итераций

**1. Вычисление собственных векторов методом обратных итераций.** Многие из методов решения проблем собственных значений лучше приспособлены для вычисления собственных значений, чем собственных векторов. Поэтому целесообразно рассмотреть задачу вычисления собственного вектора  $e_j$  при условии, что уже найдено достаточно точное приближение  $\lambda_j^*$  к собственному значению  $\lambda_j$ .

Если исходить непосредственно из определения собственного вектора, то  $e_j$  следует искать как нетривиальное решение однородной системы уравнений

$$(A - \lambda_j E)x = 0 \quad (8.24)$$

с вырожденной матрицей  $A - \lambda_j E$ . Однако  $\lambda_j$  известно лишь приближенно и в действительности при таком подходе вместо системы (8.24) придется решать систему

$$(A - \lambda_j^* E)x = 0. \quad (8.25)$$

Так как матрица  $A - \lambda_j^* E$  заведомо невырождена, то решением системы (8.25) является только  $x = 0$ . Следовательно, непосредственное численное решение системы (8.25) не дает возможность вычислить собственный вектор.

Одним из эффективных методов вычисления собственных векторов является *метод обратных итераций*. В этом методе приближения к собственному вектору определяют последовательным решением систем уравнений

$$(A - \lambda_j^* E)y^{(k+1)} = x^{(k)} \quad (8.26)$$

с последующей нормировкой решения:



$$\mathbf{x}^{(k+1)} = \frac{\mathbf{y}^{(k+1)}}{\|\mathbf{y}^{(k+1)}\|}. \quad (8.27)$$

В качестве начального приближения берут ненулевой вектор  $\mathbf{x}^{(0)}$  с произвольно выбираемыми или даже случайными компонентами. Часто удовлетворительным является выбор  $\mathbf{x}^{(0)} = (1, 1, \dots, 1)^T$ .

Чтобы понять механизм действия метода, рассмотрим случай, когда  $A$  — матрица простой структуры, а  $\lambda_j$  — простое собственное значение. Представим векторы  $\mathbf{x}^{(0)}$  и  $\mathbf{y}^{(1)}$  в виде линейных комбинаций собственных векторов  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_m$ :

$$\mathbf{x}^{(0)} = \sum_{i=1}^m c_i \mathbf{e}_i, \quad \mathbf{y}^{(1)} = \sum_{i=1}^m \alpha_i \mathbf{e}_i.$$

Так как  $(A - \lambda_j^* E) \mathbf{y}^{(1)} = \sum_{i=1}^m \alpha_i (\lambda_i - \lambda_j^*) \mathbf{e}_i$ , то систему уравнений (8.26) при  $k = 0$  можно записать в виде

$$\sum_{i=1}^m \alpha_i (\lambda_i - \lambda_j^*) \mathbf{e}_i = \sum_{i=1}^m c_i \mathbf{e}_i.$$

Приравнивая коэффициенты при  $\mathbf{e}_i$ , получим  $\alpha_i = \frac{c_i}{\lambda_i - \lambda_j^*}$ . Следовательно,

$$\mathbf{y}^{(1)} = \sum_{i=1}^m \frac{c_i}{\lambda_i - \lambda_j^*} \mathbf{e}_i = \frac{1}{\lambda_j - \lambda_j^*} (c_j \mathbf{e}_j + \sum_{i \neq j}^m \frac{\lambda_j - \lambda_j^*}{\lambda_i - \lambda_j^*} c_i \mathbf{e}_i). \quad (8.28)$$

Если  $|\lambda_j - \lambda_j^*| \ll |\lambda_i - \lambda_j^*|$  для всех  $i \neq j$ , то второе слагаемое в правой части формулы (8.28) мало по сравнению с первым. Поэтому  $\mathbf{y}^{(1)} \approx \frac{c_j}{\lambda_j - \lambda_j^*} \mathbf{e}_j$  и вектор  $\mathbf{y}^{(1)}$  оказывается близким по направлению к вектору  $\mathbf{e}_j$ .

Можно показать, что вектор  $\mathbf{x}^{(k)}$ , вычисляемый на  $k$ -й итерации, имеет вид

$$\mathbf{x}^{(k)} = \beta^{(k)} \left[ c_j \mathbf{e}_j + \sum_{i \neq j}^m \left[ \frac{\lambda_j - \lambda_j^*}{\lambda_i - \lambda_j^*} \right]^k c_i \mathbf{e}_i \right],$$

где  $|\beta^{(k)}| \rightarrow |c_j^{-1}|$  при  $k \rightarrow \infty$ . Вектор  $\mathbf{x}^{(k)}$  сходится к  $\mathbf{e}_j$  по направлению со скоростью геометрической прогрессии, знаменатель которой  $q = \max_{i \neq j} \frac{|\lambda_j - \lambda_j^*|}{|\lambda_i - \lambda_j^*|}$ .

Если абсолютная погрешность значения  $\lambda_j^*$  много меньше расстояния от  $\lambda_j$  до ближайшего из остальных собственных чисел (что эквивалентно выполнению условия  $|\lambda_j - \lambda_j^*| \ll |\lambda_i - \lambda_j^*|$  для всех  $i \neq j$ ), то метод обратных итераций сходится очень быстро. Чаще всего достаточно сделать 1–3 итерации.

**Пример 8.6.** Используя метод обратных итераций, найдем на 6-разрядной десятичной ЭВМ собственный вектор матрицы (8.4), отвечающий собственному значению  $\lambda_1 \approx \lambda_1^* = -7.8728$ .

Возьмем  $\mathbf{x}^{(0)} = (1, 1, 1)^T$ . Тогда система (8.26) при  $k = 0$  примет вид

$$\begin{aligned} 9.8728y_1 - 9y_2 + 5y_3 &= 1, \\ 1.2y_1 + 2.4729y_2 + 6y_3 &= 1, \\ y_1 - y_2 + 0.3728y_3 &= 1. \end{aligned}$$

Вычисляя ее решение методом Гаусса, получим  $y_1^{(1)} = -123909$ ,  $y_2^{(1)} = 99398.3$ ,  $y_3^{(1)} = 65749$ . После нормировки имеем  $x_1^{(1)} = -0.720736$ ,  $x_2^{(1)} = -0.578166$ ,  $x_3^{(1)} = 0.382440$ .

Подставляя в правую часть системы (8.26) вместо вектора  $\mathbf{x}^{(0)}$  вектор  $\mathbf{x}^{(1)}$  и вычисляя решение, находим  $y_1^{(2)} = -59671.5$ ,  $y_2^{(2)} = -47867.7$ ,  $y_3^{(2)} = 31663.1$ . Полученные после нормировки значения  $x_1^{(2)} = -0.720737$ ,  $x_2^{(2)} = -0.578166$ ,  $x_3^{(2)} = 0.382440$  с машинной точностью совпадают со значениями, полученными на первой итерации. Итерации следует прервать и считать результатом вектор  $\mathbf{e}_1 \approx (-0.720737, -0.578166, 0.382440)^T$ .

**З а м е ч а н и е 1.** Так как  $\lambda_j^*$  почти совпадает со значением  $\lambda_j$ , при котором  $\det(A - \lambda_j E) = 0$ , то матрица  $A - \lambda_j^* E$  очень плохо обусловлена. Возникает естественное опасение, что большие погрешности, неизбежные при реализации вычислительного процесса (8.26), (8.27) на ЭВМ, могут существенно повлиять на свойства приближений. К счастью, это не так; ошибка, возникающая при

численном решении системы (8.26) (которая может быть по величине сравнима с  $\mathbf{y}^{(k)}$ ), оказывается почти пропорциональной вектору  $\mathbf{e}_j$ . В данном случае плохая обусловленность системы не ухудшает, а улучшает ситуацию.

В справедливости сказанного легко убедиться, если повторить вычисления из примера 8.5, используя микрокалькулятор. Полученные значения  $\mathbf{y}^{(1)}$  и  $\mathbf{y}^{(2)}$  наверняка будут иметь мало общего с указанными в примере. Тем не менее приближения  $\mathbf{x}^{(1)}$  и  $\mathbf{x}^{(2)}$  практически совпадут с вычисленными выше, отличаясь, возможно, только знаком.

**З а м е ч а н и е 2.** Записав равенство (8.26) в виде  $\mathbf{y}^{(k+1)} = (A - \lambda_j^* E)^{-1} \mathbf{x}^{(k)}$ , замечаем, что метод обратных итераций — это просто степенной метод, примененный к матрице  $(A - \lambda_j^* E)^{-1}$ .

**2. Метод обратных итераций с использованием отношения Рэлея.** Одной из проблем применения метода обратных итераций является необходимость получения хорошего приближения к собственному значению. В случае, когда  $A$  — симметричная матрица, можно попытаться использовать для оценки  $\lambda_j$  отношение Рэлея. Этот подход приводит к следующему комбинированному методу:

$$\lambda^{(k)} = \rho(\mathbf{x}^{(k)}) = (A\mathbf{x}^{(k)}, \mathbf{x}^{(k)}), \quad k \geq 0, \quad (8.29)$$

$$(A - \lambda^{(k)} E) \mathbf{y}^{(k+1)} = \mathbf{x}^{(k)}, \quad (8.30)$$

$$\mathbf{x}^{(k+1)} = \frac{\mathbf{y}^{(k+1)}}{\|\mathbf{y}^{(k+1)}\|}. \quad (8.31)$$

Предполагается, что начальный вектор  $\mathbf{x}^{(0)}$  нормирован, т.е.  $\|\mathbf{x}^{(0)}\| = 1$ .

Если начальное приближение хорошо аппроксимирует по направлению вектор  $\mathbf{e}_j$ , то метод (8.29) — (8.31) сходится очень быстро. Например, если  $\lambda_j$  — простое собственное значение, то сходимость оказывается кубической. Одним из способов получения удовлетворительного начального приближения  $\mathbf{x}^{(0)}$  является выполнение нескольких итераций степенного метода.

**З а м е ч а н и е.** В случае, когда метод (8.29) — (8.31) сходится, он позволяет одновременно эффективно вычислять и собственное значение  $\lambda_j$  и соответствующий собственный вектор  $\mathbf{e}_j$ .

## § 8.4. QR-алгоритм

В настоящее время лучшим методом вычисления всех собственных значений квадратных заполненных матриц общего вида (умеренного порядка) является QR-алгоритм<sup>1</sup>.

**1. Основной QR-алгоритм.** Опишем итерационную процедуру, являющуюся основой алгоритма. Она существенно использует возможность разложения произвольной матрицы в произведение ортогональной и верхней треугольной матриц, т.е. так называемое QR-разложение (см. § 5.10).

На 1-й итерации с помощью метода отражений или метода вращений вычисляют QR-разложение матрицы  $A^{(0)} = A$ , имеющее вид

$$A^{(0)} = Q_1 R_1. \quad (8.32)$$

Затем строят матрицу  $A^{(1)} = R_1 Q_1$ . Заметим, что из равенства (8.32) следует, что  $R_1 = Q_1^{-1} A^{(0)}$  и поэтому  $A^{(1)} = Q_1^{-1} A^{(0)} Q_1$ . Таким образом, матрицы  $A^{(1)}$  и  $A^{(0)}$  подобны (см. § 8.1) и поэтому имеют общий набор собственных значений  $\lambda_1, \lambda_2, \dots, \lambda_m$ .

На 2-й итерации находят QR-разложение матрицы  $A^{(1)}$ , имеющее вид  $A^{(1)} = Q_2 R_2$ , и вычисляют матрицу  $A^{(2)} = R_2 Q_2$ , подобную матрице  $A^{(1)}$ .

На  $(k+1)$ -й итерации вычисляют разложение  $A^{(k)} = Q_{k+1} R_{k+1}$  и строят матрицу  $A^{(k+1)} = R_{k+1} Q_{k+1}$ . Неограниченное продолжение этого процесса дает последовательность матриц  $A^{(1)}, A^{(2)}, \dots, A^{(n)}, \dots$ , подобных матрице  $A$ .

К сожалению, в общем случае, когда собственные значения матрицы могут быть кратными или комплексными, строгое изложение предельных свойств последовательности  $A^{(k)}$  потребовало бы введения ряда довольно сложных математических понятий. Поэтому ограничимся указанием на то, что при определенных условиях в случае, когда собственные значения матрицы  $A$  вещественны и различны по модулю, причем  $|\lambda_1| > |\lambda_2| > \dots > |\lambda_m|$ , последовательность  $A^{(n)}$  сходится к верхней треугольной матрице  $\Lambda$  вида

$$\Lambda = \begin{bmatrix} \lambda_1 & \times & \dots & \times \\ 0 & \lambda_2 & \times & \dots & \times \\ 0 & 0 & \lambda_3 & \dots & \times \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & \lambda_m \end{bmatrix}. \quad (8.33)$$

<sup>1</sup> Этот метод независимо был предложен в 1960 г. в России математиком В.Н.Кублановской и в 1961 г. в Англии системным программистом Дж.Фрэнсисом.

Здесь крестиками помечены элементы, в общем случае не равные нулю.

Известно, что в рассматриваемом случае элементы  $a_{ij}^{(k)}$  матриц  $A^{(k)}$ , стоящие ниже главной диагонали, сходятся к нулю со скоростью геометрической прогрессии, причем

$$|a_{ij}^{(k)}| \leq C \left| \frac{\lambda_i}{\lambda_j} \right|^k, \quad i > j, \quad (8.34)$$

т.е. скорость сходимости  $a_{ij}^{(k)}$  к нулю определяется величиной отношения  $\lambda_i$  к  $\lambda_j$  (заметим, что  $\left| \frac{\lambda_i}{\lambda_j} \right| < 1$  при  $i > j$ ).

Следует подчеркнуть, что  $QR$ -алгоритм не обеспечивает обычной поэлементной сходимости и речь идет о *сходимости* к треугольной матрице (8.33) *по форме*. Она характеризуется сходимостью к нулю поддиагональных элементов, тогда как наддиагональные элементы от итерации к итерации могут существенно изменяться.

**2. Ускорение  $QR$ -алгоритма.** Приведенный выше вариант  $QR$ -алгоритма очень неэффективен по двум основным причинам. Первая из них состоит в том, что для реализации только лишь одной итерации этого метода требуется выполнить порядка  $m^3$  арифметических операций, если  $A$  — матрица общего вида. Вторая причина заключается в том, что при наличии двух близких собственных значений  $\lambda_i \approx \lambda_{i-1}$  метод сходится очень медленно, так как, например, элемент  $a_{i,i-1}^{(k)}$  сходится к нулю со скоростью геометрической прогрессии, знаменатель которой  $q = \left| \frac{\lambda_i}{\lambda_{i-1}} \right| \approx 1$ .

Для того чтобы уменьшить число арифметических операций, матрицу  $A$  предварительно с помощью подобных преобразований отражения или вращения приводят к так называемой *форме Хессенберга*<sup>1</sup>:

$$H = \begin{bmatrix} h_{11} & h_{12} & \dots & h_{1,m-1} & h_{1m} \\ h_{21} & h_{22} & \dots & h_{2,m-1} & h_{2m} \\ 0 & h_{32} & \dots & h_{3,m-1} & h_{3m} \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & h_{m,m-1} & h_{mm} \end{bmatrix}. \quad (8.35)$$

Матрица  $H$ , в которой равны нулю все элементы  $h_{ij}$ , такие, что  $i > j +$

<sup>1</sup> Герхард Хессенберг (1874 — 1925) — немецкий математик.

+ 1 (т.е. все элементы, расположенные ниже диагонали, непосредственно примыкающей к главной диагонали), называется *матрицей Хессенберга*. Существуют эффективные стандартные процедуры преобразования матрицы  $A$  к виду (8.35), поэтому мы не будем останавливаться подробно на этом преобразовании. Для дальнейшего важно то, что матрицы  $A$  и  $H$  подобны и обладают общим набором собственных значений, а матрица подобия  $P$ , для которой выполняется равенство

$$H = P^{-1}AP, \quad (8.36)$$

ортогональна.

После преобразования матрицы  $A$  к виду (8.35) к матрице  $H$  применяют  $QR$ -алгоритм. Эффективность такого подхода обусловлена наличием следующих двух замечательных свойств матриц Хессенберга.

1°. Матрицы  $H^{(k)}$ , порождаемые  $QR$ -алгоритмом из матрицы  $H^{(0)} = H$ , сами являются матрицами Хессенберга, т.е. для них  $h_{ij}^{(k)} = 0$  при  $i > j + 1$ .

2°. Для выполнения одной итерации  $QR$ -алгоритма для матрицы Хессенберга требуется число арифметических операций, пропорциональное  $m^2$ .

Однако, как уже было отмечено, даже достигнутая благодаря предварительному преобразованию матрицы  $A$  к виду (8.35) существенная экономия числа арифметических операций недостаточна для практического использования  $QR$ -алгоритма. Дело в том, что при наличии близких соседних собственных значений  $\lambda_i \approx \lambda_{i-1}$  элемент  $h_{i,i-1}^{(k)}$  убывает

очень медленно пропорционально  $q^k$ , где  $q = \left| \frac{\lambda_i}{\lambda_{i-1}} \right| \approx 1$ . Для решения этой проблемы используют различные варианты  $QR$ -алгоритма со сдвигами.

Поясним суть этого подхода. Допустим, что для  $\lambda_i$  известно хорошее приближение  $\lambda_i^*$ . Тогда собственными значениями матрицы

$\tilde{H}^{(k)} = H^{(k)} - \lambda_i^* E$  являются  $\tilde{\lambda}_j = \lambda_j - \lambda_i^*$ ,  $j = 1, 2, \dots, m$ . В этом случае вместо отношения  $\frac{\lambda_i}{\lambda_{i-1}} \approx 1$  скорость убывания поддиагонального

элемента  $h_{i,i-1}^{(k)}$  определяет величина  $\frac{\tilde{\lambda}_i}{\tilde{\lambda}_{i-1}} = \frac{\lambda_i - \lambda_i^*}{\lambda_{i-1} - \lambda_i^*} \approx 0$ . После

нескольких итераций  $QR$ -алгоритма, которые практически сделают элемент  $h_{i,i-1}^{(k)}$  равным нулю, следует выполнить обратный сдвиг, пола-

гая  $H^{(k)} = \tilde{H}^{(k)} + \lambda_i^* E$ . После выполнения этой операции матрицы  $A$  и  $H^{(k)}$  снова имеют общий набор собственных значений.

Последовательное осуществление сдвигов для  $i = m, m-1, \dots, 1$ , сопровождаемых итерациями по  $QR$ -алгоритму, дает возможность быстро привести матрицу  $A$  к виду (8.33). Остающийся невыясненным вопрос о том, как получить приближенные значения  $\lambda_i^* \approx \lambda_i$ , снимается, если учесть, что в ходе  $QR$ -алгоритма диагональные элементы  $h_{ii}^{(k)}$  сходятся к  $\lambda_i$  при  $k \rightarrow \infty$ . Следовательно, в качестве  $\lambda_i^*$  можно, например, брать элементы<sup>1</sup>  $h_{ii}^{(k)}$ .

Итак, прежде чем применять  $QR$ -алгоритм, следует преобразовать исходную матрицу  $A$  к форме Хессенберга. Без такого преобразования  $QR$ -алгоритм практически не применяется. Затем целесообразно использовать один из вариантов  $QR$ -алгоритма со сдвигами.

Пусть теперь собственные значения найдены и требуется найти один собственный вектор  $e_j$  матрицы  $A$ , отвечающий собственному значению  $\lambda_j$ , или несколько собственных векторов. Тогда целесообразно сначала найти соответствующий собственный вектор  $v_j$  матрицы  $H$  (например, методом обратных итераций), а затем вычислить  $e_j$  по формуле  $e_j = P \cdot v_j$ , где  $P$  — матрица подобия из (8.36).

**З а м е ч а н и е 1.** Вычисление собственного вектора  $e_j$  непосредственным применением метода обратных итераций к матрице  $A$  возможно, но потребует большего числа арифметических операций по сравнению с указанным выше подходом.

**З а м е ч а н и е 2.** Проведенное в этом параграфе обсуждение алгоритма носило в значительной степени ознакомительный характер. Практически не был затронут случай, когда матрица имеет кратные или комплексные собственные значения. Не рассматривались и особенности применения  $QR$ -алгоритма для комплексных матриц.

**З а м е ч а н и е 3.**  $QR$ -алгоритм обладает хорошей обусловленностью. Например, как показано в [19], в одном из его вариантов после числа итераций, не превосходящего 5, для каждого собственного значения получаются приближения  $\lambda_1^*, \lambda_2^*, \dots, \lambda_m^*$ , являющи-

---

<sup>1</sup> Чаще всего в библиотечных программах используется либо указанная стратегия сдвигов (*сдвигов по Рэлю*), либо стратегия *сдвигов по Уилкинсону* [84].

еся точными собственными значениями некоторой матрицы  $A_*$  такой, что

$$\|A - A_*\|_E \leq 30 m^2 \varepsilon_m \|A\|_E$$

(это утверждение сформулировано в терминах обратного анализа ошибок).

### § 8.5. Дополнительные замечания

1. В данной книге не рассмотрены некоторые весьма популярные методы решения проблемы собственных значений. Изложение *метода бисекций*, *метода вращений Якоби*, *QL-алгоритма* (являющегося вариантом *QR-алгоритма*), *LR-алгоритма* и других методов можно найти, например в [19], [20], [62], [83], [84].

Авторы советуют обратить внимание на книгу [41], содержащую изложение современных численных методов решения проблемы собственных значений, вполне доступное для студента или выпускника технического вуза.

2. Если  $A$  — заполненная матрица общего вида умеренного порядка, то лучшим выбором для вычисления всех собственных значений служит один из вариантов *QR-алгоритма* со сдвигами. Необходимо только предварительно преобразовать матрицу к форме Хессенберга.

3. В случае, когда  $A$  — симметричная матрица умеренного порядка, ее обычно приводят сначала с помощью последовательных преобразований Хаусхолдера к трехдиагональному виду. Для вычисления собственных значений полученной трехдиагональной матрицы можно использовать *QR-алгоритм*, но по-видимому, чаще более предпочтительным является метод бисекций. Одно из достоинств этого алгоритма состоит в том, что он позволяет находить не все собственные значения, а одно или группу нужных собственных значений.

4. Если приближенное значение собственного числа найдено, то подходящим методом вычисления соответствующего собственного вектора является метод обратных итераций.

5. Методы, которые используются в настоящее время для решения проблемы собственных значений в случае, когда  $A$  — разреженная матрица большой размерности, можно разделить на две основные группы: *методы одновременных итераций* (или *итерирования подпространства*) и *методы типа Ланцоша*. Их обсуждение можно найти, например, в [41]. Один из простейших возможных подходов — степенной метод — был рассмотрен в § 8.2.



## МЕТОДЫ ОДНОМЕРНОЙ МИНИМИЗАЦИИ

Одно из важнейших направлений в конструировании изделий, а также проектировании и эксплуатации технологических процессов состоит в оптимизации (минимизации или максимизации) некоторой характеристики  $f(x)$ . Функцию  $f(x)$  часто называют *целевой функцией*. Заметим, что основное внимание может быть уделено минимизации целевой функции, так как максимизация сводится к минимизации с помощью введения новой целевой функции  $\tilde{f}(x) = -f(x)$ . В случае, когда варьируется один скалярный параметр  $x$ , возникает *задача одномерной минимизации*.

Необходимость изучения методов решения задачи одномерной минимизации определяется не только тем, что задача может иметь самостоятельное значение, но и в значительной мере тем, что алгоритмы минимизации являются существенной составной частью алгоритмов решения задач многомерной минимизации (см. гл. 10), а также других вычислительных задач.

### § 9.1. Задача одномерной минимизации

**1. Постановка задачи. Определения.** Пусть  $f(x)$  — действительная функция одной переменной, определенная на множестве  $X \subset (-\infty, \infty)$ .

Напомним, что точка  $\bar{x} \in X$  называется *точкой глобального минимума* функции  $f$  на множестве  $X$ , если для всех  $x \in X$  выполняется неравенство  $f(\bar{x}) \leq f(x)$ . В этом случае значение  $f(\bar{x})$  называется *минимальным значением функции  $f$  на  $X$* .

Точка  $\bar{x} \in X$  называется *точкой локального минимума* функции  $f$ , если существует такая  $\delta$ -окрестность этой точки, что для всех  $x$  из множества  $X$ , содержащихся в указанной  $\delta$ -окрестности, выполняется неравенство  $f(\bar{x}) \leq f(x)$ . Если же для всех таких  $x$ , не совпадающих с

$\bar{x}$ , выполняется неравенство  $f(\bar{x}) < f(x)$ , то  $\bar{x}$  называется *точкой строго локального минимума*.

**Пример 9.1.** Для функции, график которой изображен на рис. 9.1, точки  $\bar{x}_3$  и  $\bar{x}_4$  являются точками строго локального минимума, а в точках  $x$ , удовлетворяющих неравенству  $\bar{x}_1 \leq x \leq \bar{x}_2$ , реализуется нестрогий локальный минимум.

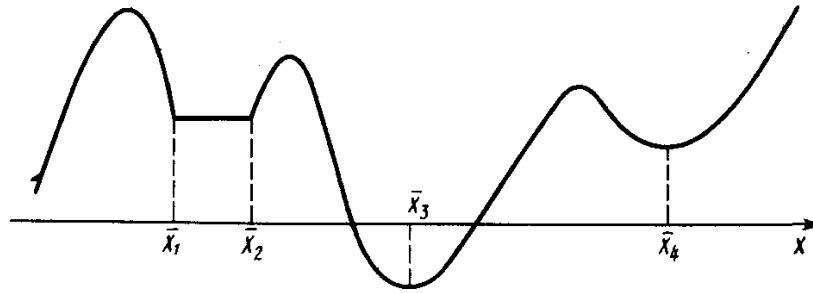


Рис. 9.1

Известно, что необходимым условием того, чтобы внутренняя для множества  $X$  точка  $\bar{x}$  была точкой локального минимума дифференцируемой функции  $f$ , является выполнение равенства

$$f'(\bar{x}) = 0. \quad (9.1)$$

Число  $\bar{x}$ , удовлетворяющее этому равенству, называется *стационарной точкой функции  $f$* . Конечно, не всякая стационарная точка  $\bar{x}$  обязана быть точкой локального минимума. Для дважды непрерывно дифференцируемой функции достаточным условием того, чтобы стационарная точка  $\bar{x}$  была точкой строго локального минимума, является выполнение неравенства  $f''(\bar{x}) > 0$ .

Существуют различные постановки задачи минимизации. В самой широкой постановке требуется найти все точки локального минимума и отвечающие им значения функции  $f$ . В приложениях чаще всего возникает задача вычисления конкретной точки локального минимума или точки глобального минимума. Иногда представляет интерес только лишь минимальное значение целевой функции, независимо от того, в какой именно точке оно достигается.

**2. Отрезок локализации.** Подобно тому, как алгоритмы решения нелинейных уравнений настроены на отыскание одного изолированно-

го корня (см. гл. 4), большинство алгоритмов минимизации осуществляет лишь поиск точки локального минимума функции  $f$ . Для того чтобы применить один из таких алгоритмов минимизации, следует предварительно найти содержащий точку  $\bar{x}$  отрезок  $[a, b]$ , на котором она является единственной точкой локального минимума. Этот отрезок в дальнейшем будем называть *отрезком локализации*<sup>1</sup> точки  $\bar{x}$ . К сожалению, не существует каких-либо общих рецептов относительно того, как найти отрезок локализации. В одномерном случае полезным может оказаться табулирование функции с достаточно мелким шагом и (или) построение графика. Отрезок  $[a, b]$  может быть известен из физических соображений, из опыта решения аналогичных задач и т. д. Для некоторых алгоритмов (например, для метода Ньютона) достаточно иметь не отрезок локализации, а хорошее начальное приближение  $x^{(0)}$  к  $\bar{x}$ .

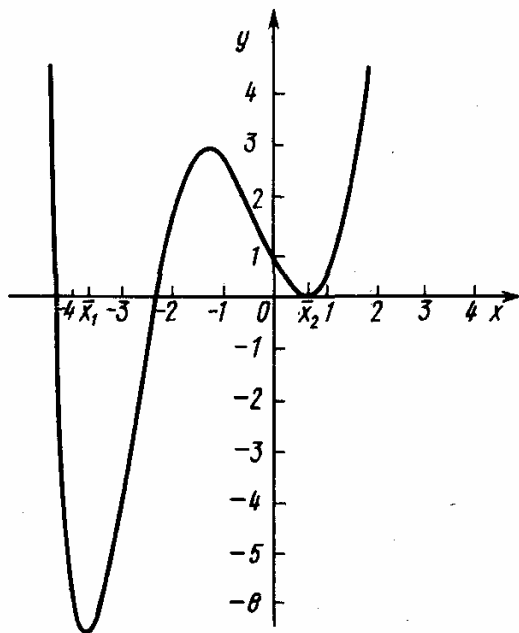


Рис. 9.2

**Пример 9.2.** Для функции  $f(x) = x^3 - x + e^{-x}$  произведем локализацию точек локального минимума.

Из графика функции, изображенного на рис. 9.2, видно, что функция  $f(x)$  имеет две точки локального минимума  $\bar{x}_1$  и  $\bar{x}_2$ , первая из которых является и точкой глобального минимума. Для точки  $\bar{x}_1$  за отрезок локализации можно принять отрезок  $[-4, -3]$ , а для точки  $\bar{x}_2$  — отрезок  $[0, 1]$ .

Докажем теперь, что на отрезке  $[0, 1]$  действительно содержится точка локального минимума. Для этого заметим, что  $f'(x) = 3x^2 - 1 - e^{-x}$  и  $f'(0) = -2 < 0$ ,  $f'(1) = 2 - e^{-1} > 0$ . Так как значения

$f'(0)$  и  $f'(1)$  имеют разные знаки, то на отрезке  $[0, 1]$  содержится точка  $\bar{x}$ , для которой  $f'(\bar{x}) = 0$ . Но  $f''(x) = 6x + e^{-x} > 0$  для всех  $x \in [0, 1]$ . Следовательно,  $f''(\bar{x}) > 0$  и точка  $\bar{x}$  на отрезке  $[0, 1]$  есть единственная точка локального ми-

<sup>1</sup> В теории оптимизации отрезок  $[a, b]$  чаще называют интервалом неопределенности. Мы понимаем интервал неопределенности иначе (см. § 9.2).

нимума. Аналогично доказывается, что отрезок  $[-4, -3]$  также является отрезком локализации.

**3. Унимодальные функции.** Пусть  $f$  — функция, определенная на отрезке  $[a, b]$ . Предположим, что на этом отрезке содержится единственная точка  $\bar{x}$  локального минимума функции  $f$ , причем функция строго убывает при  $x \leq \bar{x}$  и строго возрастает при  $x \geq \bar{x}$ . Такая функция называется *унимодальной*<sup>1</sup>. Возможны три случая расположения точки  $\bar{x}$  на отрезке  $[a, b]$ : точка  $\bar{x}$  является внутренней для отрезка,  $\bar{x}$  совпадает с левым концом отрезка и  $\bar{x}$  совпадает с правым концом отрезка. Соответственно и график унимодальной функции может иметь одну из форм, схематично изображенных на рис. 9.3.

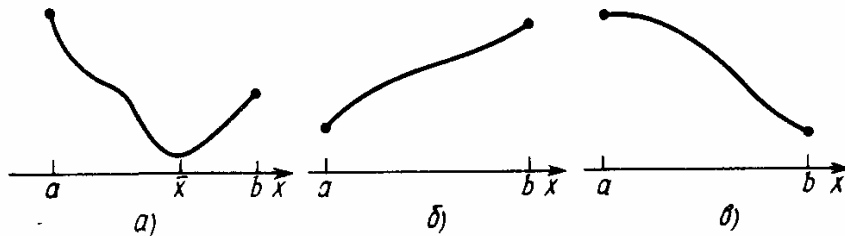


Рис. 9.3

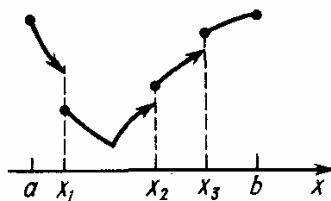


Рис. 9.4

**З а м е ч а н и е.** Унимодальная функция, вообще говоря, не обязана быть непрерывной. Например, функция, изображенная на рис. 9.4, унимодальна и имеет три точки разрыва.

Приведем достаточное условие унимодальности функций на отрезке  $[a, b]$ .

**Предложение 9.1.** Если для всех  $x \in [a, b]$  выполнено условие  $f''(x) > 0$ , то функция унимодальна на отрезке  $[a, b]$ .

**Пример 9.3.** Функция  $f(x) = x^3 - x + e^{-x}$  унимодальна на каждом из отрезков  $[-4, -3]$  и  $[0, 1]$ . Чтобы убедиться в этом, достаточно заметить, что

<sup>1</sup> Иногда такую функцию называют строго унимодальной, а унимодальной называют функцию, которая строго убывает при  $x \leq \bar{x}_1$ , равна постоянной при  $\bar{x}_1 \leq x \leq \bar{x}_2$  и строго возрастает при  $x \geq \bar{x}_2$  [18].

$f''(x) = 6x + e^{-x} > 0$  для всех  $x \in [-4, -3]$ ,  $x \in [0, 1]$ , и воспользоваться предложением 9.1.

Для сужения отрезка локализации точки минимума унимодальной функции полезно использовать следующее утверждение.

**Предложение 9.2.** Пусть  $f$  — унимодальная на отрезке  $[a, b]$  функция и  $a \leq \alpha < \gamma < \beta \leq b$ . Тогда:

1<sup>0</sup>) если  $f(\alpha) \leq f(\beta)$ , то  $\bar{x} \in [a, \beta]$ ;

2<sup>0</sup>) если  $f(\alpha) \geq f(\beta)$ , то  $\bar{x} \in [\alpha, b]$ ;

3<sup>0</sup>) если  $f(\alpha) \geq f(\gamma)$ , и  $f(\gamma) \leq f(\beta)$ , то  $\bar{x} \in [\alpha, \beta]$ .

□ 1<sup>0</sup>. Предположим противное:  $\bar{x} > \beta$ . Тогда вследствие унимодальности  $f$  получим  $f(\alpha) > f(\beta)$ , что противоречит условию.

2<sup>0</sup>. Предположим противное:  $\bar{x} < \alpha$ . Тогда вследствие унимодальности  $f$  получим  $f(\alpha) < f(\beta)$ , что противоречит условию.

3<sup>0</sup>. В силу п. 1<sup>0</sup> имеем  $\bar{x} \in [a, \beta]$ , а в силу п. 2<sup>0</sup> имеем  $\bar{x} \in [\alpha, b]$ .

Следовательно,  $\bar{x} \in [\alpha, \beta]$ .

Геометрическая иллюстрация пп. 1<sup>0</sup> и 2<sup>0</sup> приведена на рис. 9.5. ■

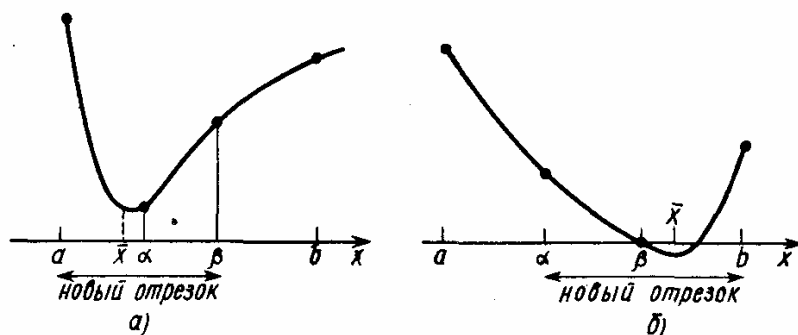


Рис. 9.5

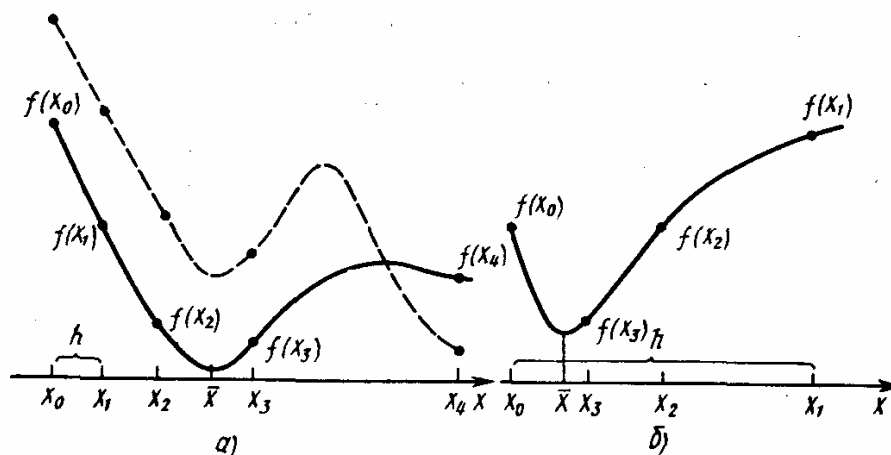


Рис. 9.6

Многие алгоритмы одномерной минимизации построены в расчете на то, что на отрезке локализации целевая функция унимодальна. В частности, такими являются алгоритмы, рассматриваемые в § 9.3.

**4. Об одном подходе к локализации точки минимума.** На практике часто бывает неизвестно, является ли данная функция унимодальной. Однако во многих случаях из дополнительных соображений следует, что при  $x \geq x_0$  функция  $f$  сначала убывает, а затем, начиная с некоторого значения  $x = \bar{x}$ , становится возрастающей (правда, не исключено, что далее она снова может стать убывающей). Для того чтобы в таком случае локализовать точку  $\bar{x}$ , используют различные нестрогие методы. Один из распространенных подходов состоит в следующем. Выбирают начальный шаг  $h > 0$ , в несколько раз меньший предполагаемого расстояния от точки  $x_0$  до точки  $\bar{x}$ . Затем вычисляют и сравнивают значения  $f(x_0)$  и  $f(x_1)$ , где  $x_1 = x_0 + h$ .

Если оказывается, что  $f(x_0) > f(x_1)$ , то последовательно вычисляют значения функции  $f$  в точках  $x_k = x_0 + 2^{k-1}h$  для  $k \geq 2$ . После обнаружения первой же точки, для которой  $f(x_k) \leq f(x_{k+1})$ , за отрезок локализации принимают отрезок  $[x_{k-1}, x_{k+1}]$ . В случае, изображенном на рис. 9.6, а, за отрезок локализации принят отрезок  $[x_2, x_4]$ .

Если же  $f(x_0) \leq f(x_1)$ , то последовательно вычисляют значения в точках  $x_k = x_0 + h/2^{k-1}$ ,  $k \geq 2$ . После обнаружения первой же точки  $x_k$ , для которой  $f(x_k) < f(x_0)$ , за отрезок локализации принимают отрезок  $[x_0, x_{k-1}]$ . В случае, изображенном на рис. 9.6, б, за отрезок локализации принят отрезок  $[x_0, x_2]$ .

Описанный метод не является строгим и не гарантирует, что отрезок локализации всегда будет найден. Например, для функции, график которой изображен пунктиром на рис. 9.6, а, при выбранном шаге  $h$  справедливы неравенства  $f(x_0) > f(x_1) > f(x_2) > f(x_3) > f(x_4)$  и поэтому отрезок локализации точки  $\bar{x}$  обнаружен уже не будет. Тем не менее этот или близкий к нему методы часто используются на практике.

**Пример 9.4.** Локализуем указанным выше образом точку локального минимума функции  $f(x) = x^3 - x + e^{-x}$ .

Возьмем  $x_0 = -5$ ,  $h = 0.2$  и положим  $x_1 = x_0 + h = -4.8$ . Так как  $f(x_0) \approx 28.4 > f(x_1) \approx 15.7$ , то будем последовательно вычислять значения функции  $f$  в точках  $x_k = x_0 + 2^{k-1}h$ . Из табл. 9.1 видно, что при  $k = 4$  впервые выполняется неравенство  $f(x_k) < f(x_{k+1})$ . Поэтому за отрезок локализации следует принять отрезок  $[x_3, x_5] = [-4.2, -1.8]$ .

Т а б л и ц а 9.1

$k$	0	1	2	3	4	5
$x_k$	-5	-4.8	-4.6	-4.2	-3.4	-1.8
$f(x_k)$	28.4	15.7	6.74	-3.30	-5.94	2.02

## § 9.2. Обусловленность задачи минимизации

Пусть  $\bar{x}$  — точка строгого локального минимума функции  $f$ , вычисляемой с погрешностью. Будем считать, что в некоторой окрестности точки  $\bar{x}$  вычисляемые приближенные значения  $f^*(x)$  удовлетворяют неравенству  $|f(x) - f^*(x)| \leq \bar{\Delta} = \bar{\Delta}(f^*)$ , т. е. имеют границу абсолютной погрешности, равную  $\bar{\Delta}$ . Как нетрудно понять, существует такая малая окрестность  $(\bar{x} - \bar{\epsilon}, \bar{x} + \bar{\epsilon})$  точки минимума  $\bar{x}$ , для которой,

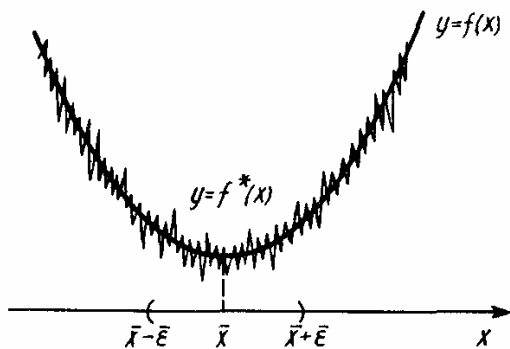


Рис. 9.7

основываясь на сравнении вычисляемых значений  $f^*(x)$ , нельзя достоверно определить ту точку, в которой действительно достигается минимум функции  $f$ . Эта ситуация схематично изображена на рис. 9.7.

Интервал  $(\bar{x} - \bar{\epsilon}, \bar{x} + \bar{\epsilon})$  будем называть *интервалом неопределенности*

точки  $\bar{x}$  локального минимума.

Оценим величину  $\bar{\epsilon}$  радиуса интервала неопределенности в предположении, что функция  $f$  дважды непрерывно дифференцируема и выполнено условие  $f''(\bar{x}) > 0$ . В этом случае с учетом того, что  $f'(\bar{x}) = 0$ , для значений функции  $f$  в точках  $x$ , близких к  $\bar{x}$ , справедливо приближенное равенство

$$f(x) \approx f(\bar{x}) + \frac{f''(\bar{x})}{2} (x - \bar{x})^2.$$

Оценим минимальное расстояние между точками  $x$  и  $\bar{x}$ , начиная с которого заведомо будет выполнено неравенство  $f^*(x) > f^*(\bar{x})$ , т. е. точка  $x$  перестанет попадать в интервал неопределенности. Имеем

$$f^*(x) - f^*(\bar{x}) = f(x) - f(\bar{x}) + (f^*(x) - f(x)) - (f^*(\bar{x}) - f(\bar{x})) \geq \\ \geq f(x) - f(\bar{x}) - 2\bar{\Delta} \approx \frac{f''(\bar{x})}{2} (x - \bar{x})^2 - 2\bar{\Delta}.$$

Следовательно,  $f^*(x) - f^*(\bar{x}) \geq \frac{f''(\bar{x})}{2} (x - \bar{x})^2 - 2\bar{\Delta}$  и неравенство  $f^*(x) > f^*(\bar{x})$  выполнено, если  $(x - \bar{x})^2 \geq 4\bar{\Delta}/f''(\bar{x})$ . Таким образом,

$$\bar{\varepsilon} \approx 2 \sqrt{\bar{\Delta}/f''(\bar{x})}. \quad (9.2)$$

Заметим, что любое приближение  $\bar{x}^*$  к  $\bar{x}$ , попавшее в интервал неопределенности, нельзя отличить от точного значения  $\bar{x}$  точки минимума, используя только вычисляемые значения  $f^*$  функции  $f$ . Поэтому

$$\bar{\Delta}(\bar{x}^*) \approx 2 \sqrt{\bar{\Delta}(f^*)/f''(\bar{x})}. \quad (9.3)$$

Итак, рассматриваемую задачу минимизации нельзя назвать хорошо обусловленной. Если задача хорошо масштабирована, т. е.  $\bar{x} \sim 1$ ,  $|f(\bar{x})| \sim 1$ ,  $f''(\bar{x}) \sim 1$ , то соотношение (9.3) можно записать в терминах относительных погрешностей так:

$$\bar{\delta}(\bar{x}^*) \sim \sqrt{\bar{\delta}(f^*)}.$$

Отсюда следует, что если  $\bar{\delta}(f^*) \sim 10^{-m}$ , то  $\bar{\delta}(\bar{x}^*) \sim 10^{-m/2}$ . Иными словами, если значения функции вычисляются с  $m$  верными значащими цифрами, то приближенное значение точки минимума можно найти примерно лишь с  $m/2$  верными значащими цифрами.

Таким образом, точность определения положения точки минимума гладкой функции существенным образом зависит от точности вычисления функции  $f$ . При этом если для поиска  $\bar{x}$  используются только приближенные значения  $f^*(x)$ , вычисляемые для различных  $x$ , то неизбежна потеря примерно половины верных значащих цифр.

Предположим теперь, что для отыскания точки локального минимума можно использовать вычисляемые каким-либо образом приближенные значения  $(f')^*(x)$  производной функции  $f$ . Как уже отмечалось в § 9.1, в рассматриваемом случае задача минимизации эквивалентна задаче отыскания корня  $\bar{x}$  нелинейного уравнения  $f'(x) = 0$ . Из результатов § 4.2 вытекает, что последняя задача обладает значительно



меньшей чувствительностью к ошибкам. В частности, справедлива следующая оценка границы абсолютной погрешности:

$$\bar{\Delta}(\bar{x}^*) \approx \frac{1}{f''(\bar{x})} \bar{\Delta}((f')^*). \quad (9.4)$$

Сравнение (9.4) с оценкой (9.3) показывает, что алгоритмы, использующие для отыскания решения  $\bar{x}$  уравнения (9.1) вычисление значений производной, могут достигать более высокой точности, чем алгоритмы, использующие для минимизации функции  $f$  только вычисление ее значений.

**Пример 9.5.** Оценим радиус интервала неопределенности для каждой из точек  $\bar{x}_1 \approx -3,7$ ,  $\bar{x}_2 \approx 0,7$  локального минимума функции  $f(x) = x^3 - x + e^{-x}$  в случае, когда вычисление функции производится на 6-разрядной десятичной ЭВМ<sup>1</sup>.

Заметим, что  $f(\bar{x}_1) \approx f(-3,7) \approx -6,5$ ,  $f(\bar{x}_2) \approx f(0,7) \approx 0,14$ . Так как для используемой ЭВМ<sup>2</sup>  $\epsilon_M = 5 \cdot 10^{-7}$ , то в малой окрестности точки  $\bar{x}_1$  верхняя граница  $\bar{\Delta}_1$  абсолютной погрешности вычисления  $f$  приближенно равна  $\epsilon_M |f(\bar{x}_1)| \approx 5 \cdot 10^{-7} \cdot 6,5 = 3,25 \cdot 10^{-6}$ . Аналогично,  $\bar{\Delta}_2 \approx \epsilon_M |f(\bar{x}_2)| \approx 5 \cdot 10^{-7} \cdot 0,14 = 7 \cdot 10^{-8}$ .

Вычисляя значения второй производной  $f''(x) = 6x + e^{-x}$  при  $x = \bar{x}_1$ ,  $x = \bar{x}_2$ , получаем  $f''(\bar{x}_1) \approx 18$ ,  $f''(\bar{x}_2) \approx 4,7$ . В силу формулы (9.2) радиусы интервалов неопределенности оцениваются следующим образом:

$$\bar{\epsilon}_1 \approx 2\sqrt{\bar{\Delta}_1/f''(\bar{x}_1)} \approx 2\sqrt{3,25 \cdot 10^{-6}/18} \approx 8 \cdot 10^{-4},$$

$$\bar{\epsilon}_2 \approx 2\sqrt{\bar{\Delta}_2/f''(\bar{x}_2)} \approx 2\sqrt{7 \cdot 10^{-8}/4,7} \approx 2 \cdot 10^{-4}.$$

Следовательно, точку  $\bar{x}_2$  можно найти с большей точностью, чем точку  $\bar{x}_1$ , если использовать сравнение вычисляемых на 6-разрядной десятичной ЭВМ значе-

---

<sup>1</sup> Напомним, что 6-разрядной десятичной ЭВМ мы условились называть гипотетическую ЭВМ, имеющую 6 десятичных разрядов мантиссы и производящую округление по дополнению.

<sup>2</sup> Напомним, что через  $\epsilon_M$  обозначено машинное эpsilon — величина, характеризующая относительную точность представления чисел в ЭВМ.

ний функции  $f$ . При этом каждую из точек можно найти с точностью  $\varepsilon = 10^{-3}$ , но вряд ли удастся найти с точностью  $\varepsilon = 10^{-4}$ .

**Пример 9.6.** Пусть теперь точки  $\bar{x}_1$  и  $\bar{x}_2$  локального минимума функции  $f(x) = x^3 - x + e^{-x}$  ищутся как решения нелинейного уравнения

$$f'(x) = 3x^2 - 1 - e^{-x} = 0. \quad (9.5)$$

Оценим в этом случае радиус интервала неопределенности для каждой из точек  $\bar{x}_1, \bar{x}_2$ , если вычисления ведутся на той же ЭВМ, что и в предыдущем примере.

Оценим сначала границу абсолютной погрешности вычисления производной исходя из приближенного равенства

$$\bar{\Delta} = \bar{\Delta}(f') = \bar{\Delta}(3\bar{x}^2) + \bar{\Delta}(1) + \bar{\Delta}(e^{-\bar{x}}) \approx \varepsilon_M(3\bar{x}^2 + e^{-\bar{x}}).$$

Тогда

$$\bar{\Delta}_1 \approx \varepsilon_M(3\bar{x}_1^2 + e^{-\bar{x}_1}) \approx 4 \cdot 10^{-5}, \quad \bar{\Delta}_2 \approx \varepsilon_M(3\bar{x}_2^2 + e^{-\bar{x}_2}) \approx 10^{-6}.$$

На основании формулы (9.4) имеем

$$\bar{\varepsilon}_1 \approx \bar{\Delta}_1/f''(\bar{x}_1) \approx 2 \cdot 10^{-6}, \quad \bar{\varepsilon}_2 \approx \bar{\Delta}_2/f''(\bar{x}_2) \approx 2 \cdot 10^{-7}. \quad (9.6)$$

Заметим, что погрешности представления чисел  $\bar{x}_1, \bar{x}_2$  на 6-разрядной десятичной ЭВМ таковы:  $\varepsilon_M|\bar{x}_1| \approx 2 \cdot 10^{-6}$ ,  $\varepsilon_M|\bar{x}_2| \approx 4 \cdot 10^{-7}$ . Поэтому полученные оценки (9.6) означают, что, решая уравнение (9.5), можно найти точки  $\bar{x}_1$  и  $\bar{x}_2$  с максимальной для используемой ЭВМ точностью, равной соответственно  $2 \cdot 10^{-6}$  и  $4 \cdot 10^{-7}$  (ср. с результатом предыдущего примера).

### § 9.3. Методы прямого поиска.

**Оптимальный пассивный поиск.**

**Метод деления отрезка пополам.**

**Методы Фибоначчи и золотого сечения**

Ряд методов минимизации основан на сравнении значений функции  $f$ , вычисляемых в точках  $x_1, x_2, \dots, x_N$ . Эти методы часто называют *методами прямого поиска*, а точки  $x_i$  — *пробными точками*.

Прежде чем перейти к изложению некоторых из наиболее известных методов прямого поиска, уточним постановку задачи. Будем счи-

татель, что требуется найти приближение  $\bar{x}^*$  к точке минимума  $\bar{x}$  унимодальной на отрезке  $[a, b]$  функции  $f$ . Предположим также, что число пробных точек  $N$  заранее фиксируется и за приближение  $\bar{x}^*$  к точке минимума принимается одна из этих точек.

**1. Оптимальный пассивный поиск.** Метод решения поставленной задачи, в котором задается правило вычисления сразу всех пробных точек  $x_1, x_2, \dots, x_N$  и за  $\bar{x}^*$  принимается та точка  $x_k$ , для которой  $f(x_k) = \min_{1 \leq i \leq N} f(x_i)$ , называется *методом пассивного поиска*. Соответствующая геометрическая иллюстрация приведена на рис. 9.8.

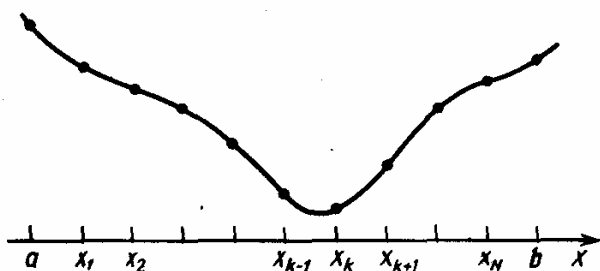


Рис. 9.8

Оценим погрешность этого метода. Для удобства положим  $x_0 = a, x_{N+1} = b$ . В силу выбора точки  $\bar{x}^* = x_k$  справедливы неравенства  $f(x_{k-1}) \geq f(x_k)$  и  $f(x_k) \leq f(x_{k+1})$ . Поэтому из п. 3<sup>о</sup> предложения 9.2 следует,

что  $\bar{x} \in [x_{k-1}, x_{k+1}]$ . Значит,  $|\bar{x} - x_k| \leq \max \{x_k - x_{k-1}, x_{k+1} - x_k\}$ . Так как положение точки минимума  $\bar{x}$  на отрезке  $[a, b]$  заранее неизвестно, то для  $\bar{x}^* = \bar{x}_k$  справедлива лишь следующая гарантированная оценка погрешности:

$$|\bar{x} - \bar{x}^*| \leq \max_{1 \leq i \leq N+1} |x_i - x_{i-1}|. \quad (9.7)$$

Можно показать, что величина, стоящая в правой части неравенства (9.7), станет минимальной, если точки  $x_1, x_2, \dots, x_N$  расположить на отрезке  $[a, b]$  равномерно в соответствии с формулой  $x_i = a + ih$ , где  $h = \Delta / (N + 1)$ ,  $\Delta = b - a$ . Метод с таким выбором пробных точек называется *оптимальным пассивным поиском*. Гарантированная оценка погрешности для него выглядит так:

$$|\bar{x} - \bar{x}^*| \leq \frac{b - a}{N + 1} = \frac{\Delta}{N + 1}. \quad (9.8)$$

**Пример 9.7.** Используем оптимальный пассивный поиск для того, чтобы найти с точностью  $\epsilon = 0.1$  точку  $\bar{x}$  локального минимума функции  $f(x) = x^3 - x + e^{-x}$ , локализованную на отрезке  $[0, 1]$ .

Из формулы (9.8) следует, что для решения задачи потребуется вычислить значения функции в девяти пробных точках вида  $x_i = 0.1i$ , где  $i = 1, 2, \dots, 9$ . Приведем таблицу этих значений:

Т а б л и ц а 9.2

$x$	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
$y$	0.81	0.63	0.47	0.33	0.23	0.17	0.14	0.16	0.24

Так как минимальное значение достигается в точке  $x_7 = 0.7$ , то  $\bar{x} = 0.7 \pm 0.1$ .

Если бы мы попытались найти  $\bar{x}$  с точностью  $\epsilon = 10^{-2}$ , то оптимальный пассивный поиск потребовал бы вычисления значений функции уже в 99 точках.

**2. Метод деления отрезка пополам.** Пусть для решения поставленной задачи последовательно вычисляются значения функции  $f$  в  $N$  пробных точках  $x_1, x_2, \dots, x_N$ , причем для определения каждой из точек  $x_k$  можно использовать информацию о значениях функции во всех предыдущих точках  $x_1, x_2, \dots, x_{k-1}$ . Соответствующие методы называют *методами последовательного поиска*. Рассмотрим простейший из методов этого семейства — *метод деления отрезка пополам*. В нем, как и в двух других рассматриваемых в этом параграфе методах (методах Фибоначчи и золотого сечения), используется принцип последовательного сокращения отрезка локализации, основанный на предложении 9.2 и на следующем простом утверждении.

**Предложение 9.3.** Если функция унимодальна на отрезке  $[a, b]$ , то она унимодальна и на любом отрезке  $[c, d] \subset [a, b]$ .

Для удобства изложения обозначим отрезок  $[a, b]$  через  $[a^{(0)}, b^{(0)}]$ . Поиск минимума начинают с выбора на отрезке  $[a^{(0)}, b^{(0)}]$  двух симметрично расположенных точек  $\alpha^{(0)} = \frac{a^{(0)} + b^{(0)}}{2} - \delta$ ,  $\beta^{(0)} = \frac{a^{(0)} + b^{(0)}}{2} + \delta$ . Здесь  $0 < \delta < \frac{b - a}{2}$ ,  $\delta$  — параметр метода. Далее вычисляют значения  $f(\alpha^{(0)})$  и  $f(\beta^{(0)})$ . Сравнение этих значений в силу предложения 9.2 позволяет сократить отрезок локализации следующим образом:

если  $f(\alpha^{(0)}) \leq f(\beta^{(0)})$ , то  $\bar{x} \in [a^{(1)}, b^{(1)}] = [a^{(0)}, \beta^{(0)}]$ ;

если  $f(\alpha^{(0)}) > f(\beta^{(0)})$ , то  $\bar{x} \in [a^{(1)}, b^{(1)}] = [\alpha^{(0)}, b^{(0)}]$ .

Если описанную процедуру принять за одну итерацию метода и продолжить аналогичные операции для образования последовательности сокращающихся отрезков локализации, то получим итерационный метод. Опишем очередную его итерацию исходя из того, что отрезок локализации  $[a^{(k)}, b^{(k)}]$  уже найден. Выполняют следующие действия:

1°. Вычисляют  $\alpha^{(k)} = \frac{a^{(k)} + b^{(k)}}{2} - \delta$ ,  $\beta^{(k)} = \frac{a^{(k)} + b^{(k)}}{2} + \delta$ .

2°. Находят значения  $f(\alpha^{(k)})$  и  $f(\beta^{(k)})$ .

3°. Новый отрезок локализации определяют по правилу:

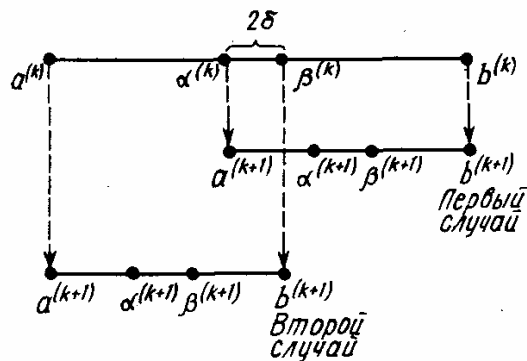


Рис. 9.9

если  $f(\alpha^{(k)}) \leq f(\beta^{(k)})$ , то  $[a^{(k+1)}, b^{(k+1)}] = [\alpha^{(k)}, \beta^{(k)}]$ ;

если  $f(\alpha^{(k)}) > f(\beta^{(k)})$ , то  $[a^{(k+1)}, b^{(k+1)}] = [a^{(k)}, \beta^{(k)}]$ .

В первом случае за очередное приближение к точке минимума принимают  $\bar{x}^{(k+1)} = \alpha^{(k)}$ , а во втором случае  $\bar{x}^{(k+1)} = \beta^{(k)}$  (рис. 9.9).

Обозначим через  $\Delta^{(n)} = b^{(n)} - a^{(n)}$  длину отрезка  $[a^{(n)}, b^{(n)}]$ .

Как нетрудно заметить, справедливо равенство

$$\Delta^{(n+1)} = \frac{\Delta^{(n)}}{2} + \delta. \quad (9.9)$$

Поэтому, если параметр  $\delta$  достаточно мал ( $\delta \ll \Delta^{(n)}$ ), то длина вновь полученного отрезка почти вдвое меньше длины предыдущего отрезка. Отсюда — и название метода.

Используя равенство (9.9), с помощью метода математической индукции легко показать, что

$$\Delta^{(n)} = \frac{(\Delta - 2\delta)}{2^n} + 2\delta.$$

Заметим, что  $\Delta^{(n)}$  убывает и при  $n \rightarrow \infty$  стремится к величине  $2\delta$ , оставаясь при каждом  $n$  больше этой величины. Поэтому сделать при некотором  $n$  длину  $\Delta^{(n)}$  отрезка локализации  $[a^{(n)}, b^{(n)}]$  меньше заданного  $\epsilon > 0$  можно лишь, выбрав  $\delta < \epsilon/2$ . В этом случае из очевидной оценки погрешности  $|x^{(n)} - \bar{x}| < \Delta^{(n)}$  следует, что значение  $\bar{x}$  действительно можно найти с точностью  $\epsilon$  и справедлив следующий критерий окончания итерационного процесса. Вычисления следует прекратить, как только окажется выполненным неравенство

$$\Delta^{(n)} \leq \epsilon. \quad (9.10)$$

Тогда за приближение к  $\bar{x}$  с точностью  $\epsilon$  можно принять  $\bar{x}^* = x^{(n)}$ .

**З а м е ч а н и е.** При реализации метода на ЭВМ необходимо учитывать, что вычисления значений функции  $f$  будут производиться с погрешностью. Для того чтобы знак разности  $f^*(\alpha^{(n)}) - f^*(\beta^{(n)})$  совпадал со знаком разности  $f(\alpha^{(n)}) - f(\beta^{(n)})$ , необходимо, чтобы выполнялось условие  $\delta \gtrsim \bar{\epsilon}$  (см. равенство (9.2)). Поэтому  $\delta$  нельзя задавать слишком малым.

**Пример 9.8.** Применяя метод деления отрезка пополам, найдем с точностью  $\epsilon = 10^{-2}$  точку  $\bar{x}$  локального минимума функции  $f(x) = x^3 - x + e^{-x}$ , локализованную на отрезке  $[0, 1]$ . Вычисления будем вести на 6-разрядной десятичной ЭВМ.

Зададим  $\delta = 10^{-3}$ ,  $a^{(0)} = 0$ ,  $b^{(0)} = 1$ .

**И т е р а ц и я.** 1. Вычислим  $\alpha^{(0)} = \frac{a^{(0)} + b^{(0)}}{2} - \delta = 0.499$ ,

$\beta^{(0)} = \frac{a^{(0)} + b^{(0)}}{2} + \delta = 0.501$ .

2. Определим значения  $f(\alpha^{(0)}) \approx 0.232389$ ,  $f(\beta^{(0)}) \approx 0.230676$ .

3. Так как  $f(\alpha^{(0)}) > f(\beta^{(0)})$ , то следует положить  $[a^{(1)}, b^{(1)}] = [0.499, 1]$ .

Результаты следующих итераций приведены в табл. 9.3.

Т а б л и ц а 9.3

$n$	$a^{(n)}$	$b^{(n)}$	$\alpha^{(n)}$ $f(\alpha^{(n)})$	$\beta^{(n)}$ $f(\beta^{(n)})$	$\Delta^{(n)}$
0	0.000000	1.000000	0.499000 0.232389	0.501000 0.230676	1.000
1	0.499000	1.000000	0.748500 0.143924	0.750500 0.144350	0.501
2	0.499000	0.750500	0.623750 0.154860	0.625750 0.154131	0.252
3	0.623750	0.750500	0.686125 0.140403	0.688125 0.140230	0.125
4	0.686125	0.750500	0.717088 0.139821	0.719088 0.139940	0.063
5	0.686125	0.719088	0.701607 0.139549	0.703607 0.139520	0.033
6	0.701607	0.719088	0.708348 0.139543	0.711348 0.139587	0.017
7	0.710141	0.719813			0.010

Так как  $\Delta^{(7)} \leq \varepsilon$ , то при  $n = 7$  итерации прекратим и положим  $\bar{x} \approx \beta^{(n)} = 0.711348$ . Таким образом,  $\bar{x} = 0.71 \pm 0.01$ . Заметим, что для достижения точности  $\varepsilon = 10^{-2}$  потребовалось 14 вычислений функции.

**3. Метод Фибоначчи.** Заметим, что метод деления отрезка пополам требует на каждой итерации вычисления двух новых значений функции, так как найденные на предыдущей итерации в точках  $\alpha^{(n)}$  и  $\beta^{(n)}$  значения далее не используются. Обратим теперь внимание на то, что одна из этих точек (обозначенная в предыдущем параграфе через  $x^{(n)}$ ) является внутренней для отрезка  $[a^{(n)}, b^{(n)}]$  и поэтому дальнейшее сокращение отрезка можно произвести, вычислив дополнительно значение функции лишь в одной новой точке. Это наблюдение приводит к методам, требующим на каждой итерации (кроме первой) расчета лишь одного нового значения функции  $f$ . Два наиболее известных среди них — методы Фибоначчи и золотого сечения.

*Метод Фибоначчи*<sup>1</sup> является оптимальным последовательным методом, т. е. методом, обеспечивающим максимальное гарантированное сокращение отрезка локализации при заданном числе  $N$  вычислений функции. Этот метод основан на использовании чисел Фибоначчи  $F_n$ , задаваемых рекуррентной формулой

$$F_n = F_{n-1} + F_{n-2} \quad (n \geq 2)$$

и начальными значениями  $F_0 = 1, F_1 = 1$ . Укажем несколько первых чисел:  $F_0 = 1, F_1 = 1, F_2 = 2, F_3 = 3, F_4 = 5, F_5 = 8, F_6 = 13, F_7 = 21, F_8 = 34, F_9 = 55, F_{10} = 89, F_{11} = 144$ .

Метод Фибоначчи состоит из  $N - 1$  шагов. Очередной  $(k + 1)$ -й шаг выполняют здесь аналогично  $(k + 1)$ -й итерации метода деления отрезка пополам. В отличие от него точки  $\alpha^{(k)}, \beta^{(k)}$  здесь находят по формулам

$$\alpha^{(k)} = a^{(k)} + \frac{F_{N-k-1}}{F_{N-k+1}} \Delta^{(k)}, \quad \beta^{(k)} = a^{(k)} + \frac{F_{N-k}}{F_{N-k+1}} \Delta^{(k)}.$$

Новый отрезок локализации определяют по тому же правилу:

если  $f(\alpha^{(k)}) \leq f(\beta^{(k)})$ , то  $[a^{(k+1)}, b^{(k+1)}] = [a^{(k)}, \beta^{(k)}]$ ;  
если  $f(\alpha^{(k)}) > f(\beta^{(k)})$ , то  $[a^{(k+1)}, b^{(k+1)}] = [\alpha^{(k)}, b^{(k)}]$ .

---

<sup>1</sup> Фибоначчи (Леонардо Пизанский) (1180—1240) — итальянский математик.

В первом случае за очередное приближение к точке минимума принимают  $x^{(k+1)} = \alpha^{(k)}$ , а во втором случае  $x^{(k+1)} = \beta^{(k)}$  (рис. 9.10).

Важно то, что в любом случае точка  $x^{(k+1)}$  совпадает с одной из точек

$$\alpha^{(k+1)} = a^{(k+1)} + \frac{F_{N-k-2}}{F_{N-k}} \Delta^{(k+1)},$$

$$\beta^{(k+1)} = a^{(k+1)} + \frac{F_{N-k-1}}{F_{N-k}} \Delta^{(k+1)}.$$

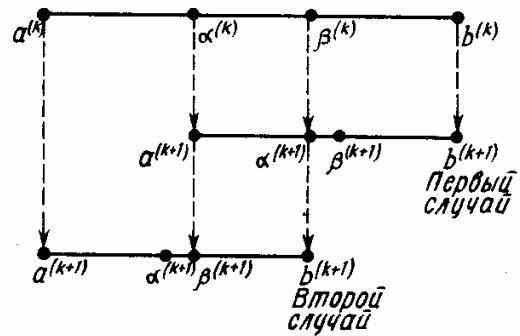


Рис. 9.10

Поэтому на очередном шаге достаточно вычислить значение функции лишь в одной недостающей точке.

В результате выполнения  $N - 1$  шагов отрезок локализации уменьшается в  $F_{N+1}/2$  раз, а точка  $x^{(N-1)}$  оказывается центральной для последнего отрезка локализации  $[a^{(N-1)}, b^{(N-1)}]$ . Поэтому для  $x^{(N-1)}$  справедлива следующая оценка погрешности:

$$|\bar{x} - x^{(N-1)}| \leq \frac{1}{F_{N+1}} \Delta. \quad (9.11)$$

**Пример 9.9.** Применяя метод Фибоначчи, найдем с точностью  $\varepsilon = 10^{-2}$  точку  $\bar{x}$  локального минимума функции  $f(x) = x^3 - x + e^{-x}$ , локализованную на отрезке  $[0, 1]$ . Вычисления будем вести на 6-разрядной десятичной ЭВМ.

Первым среди чисел Фибоначчи, для которого выполняется условие  $\Delta/F_{N+1} < \varepsilon$  (где  $\Delta = 1$ ), является число  $F_{11} = 144$ , отвечающее  $N = 10$ . Зададим  $a^{(0)} = 0$ ,  $b^{(0)} = 1$ .

**Первый шаг.** 1. Вычислим  $\alpha^{(0)} = a^{(0)} + (b^{(0)} - a^{(0)}) \frac{F_9}{F_{11}} = \frac{55}{144} \approx 0.381944$ ,  $\beta^{(0)} = a^{(0)} + (b^{(0)} - a^{(0)}) \frac{F_{10}}{F_{11}} = \frac{89}{144} \approx 0.618056$ .

2. Определим значения  $f(\alpha^{(0)}) \approx 0.356308$ ,  $f(\beta^{(0)}) \approx 0.157028$ .

3. Так как  $f(\alpha^{(0)}) > f(\beta^{(0)})$ , то положим  $[a^{(1)}, b^{(1)}] = [\alpha^{(0)}, b^{(0)}]$ .

**Второй шаг.** 1. Учитывая, что  $\alpha^{(1)} = \beta^{(0)} \approx 0.618056$ , вычислим  $\beta^{(1)} = a^{(1)} + (b^{(1)} - a^{(1)}) \frac{F_9}{F_{10}} \approx 0.763889$ .

2. Вычислим значение  $f(\beta^{(1)}) \approx 0.147712$ .

3. Так как  $f(\alpha^{(1)}) > f(\beta^{(1)})$ , то положим  $[a^{(2)}, b^{(2)}] = [\alpha^{(1)}, b^{(1)}]$ .

Результаты остальных шагов приведены в табл. 9.4.



Т а б л и ц а 9.4

$n$	$a^{(n)}$	$b^{(n)}$	$\alpha^{(n)}$ $f(\alpha^{(n)})$	$\beta^{(n)}$ $f(\beta^{(n)})$	$\Delta^{(n)}$
0	0.000000	1.000000	0.381944 0.356308	0.618056 0.157028	1.000
1	0.381944	1.000000	0.618056 0.157028	0.763889 0.147712	0.618
2	0.618056	1.000000	0.763889 0.147712	0.854167 0.194672	0.382
3	0.618056	0.854167	0.708334 0.139527	0.763889 0.147712	0.236
4	0.618056	0.763889	0.673611 0.141905	0.708334 0.139527	0.119
5	0.673611	0.763889	0.708334 0.139527	0.729167 0.140830	0.090
6	0.673611	0.729167	0.694445 0.139805	0.708334 0.139527	0.056
7	0.694445	0.729167	0.708334 0.139527	0.715278 0.139731	0.035
8	0.694445	0.715278	0.701389 0.139553	0.708334 0.139527	0.021
9	0.701389	0.715278	0.708334	0.708334	0.014

После 9 шагов вычисления прекращаем и полагаем  $\bar{x} \approx \beta^{(8)} = 0.708334$ . Таким образом,  $\bar{x} = 0.71 \pm 0.01$ . Заметим, что для достижения точности  $\varepsilon = 10^{-2}$  потребовалось 10 вычислений значения функции, в то время как при использовании метода деления отрезка пополам необходимо 14 вычислений.

Хотя метод Фибоначчи и оптимален в указанном выше смысле, зачастую он неудобен для использования. В частности, это касается возможного применения поиска Фибоначчи для решения одномерных подзадач в алгоритмах многомерной минимизации. Здесь нередко эффективность алгоритма одномерной минимизации оценивается не по тому, какая точность в значении  $\bar{x}$  получена, а совсем по другим критериям, к которым метод плохо приспособлен. Например, бывает важно достичь минимального значения функции  $f$  с некоторой относительной точностью  $\delta$  либо уменьшить значение  $f$  на определенную величину.

**4. Метод золотого сечения.** Из-за указанных недостатков вместо

метода Фибоначчи чаще используется теоретически почти столь же эффективный *метод золотого сечения*.

Напомним, что *золотым сечением*<sup>1</sup> отрезка называется такое разбиение отрезка на две неравные части, что отношение длины всего отрезка к длине его большей части равно отношению длины большей части к длине меньшей части отрезка.

Золотое сечение отрезка  $[a, b]$  осуществляется каждой из двух симметрично расположенных относительно центра отрезка точек

$$\alpha = a + \frac{2}{3 + \sqrt{5}} (b - a), \quad \beta = a + \frac{2}{1 + \sqrt{5}} (b - a)$$

(рис. 9.11). Действительно, как нетрудно проверить,

$$\frac{b - a}{b - \alpha} = \frac{b - \alpha}{\alpha - a} = \frac{1 + \sqrt{5}}{2}, \quad \frac{b - a}{\beta - a} = \frac{\beta - a}{b - \beta} = \frac{1 + \sqrt{5}}{2}.$$

Замечательно то, что точка  $\alpha$  осуществляет золотое сечение не только отрезка  $[a, b]$ , но и отрезка  $[a, \beta]$ .

Действительно,  $\frac{\beta - a}{\alpha - a} = \frac{\alpha - a}{\beta - \alpha} = \frac{1 + \sqrt{5}}{2}$ .



Рис. 9.11

Точно так же точка  $\beta$  осуществляет золотое сечение не только отрезка  $[a, b]$ , но и отрезка  $[\alpha, b]$ . Этот факт далее существенно используется.

Очередная  $(k + 1)$ -я итерация метода золотого сечения производится аналогично  $(k + 1)$ -й итерации метода деления отрезка пополам. В отличие от него точки  $\alpha^{(k)}$ ,  $\beta^{(k)}$  находятся по формулам

$$\alpha^{(k)} = a^{(k)} + \frac{2}{3 + \sqrt{5}} \Delta^{(k)}, \quad \beta^{(k)} = a^{(k)} + \frac{2}{1 + \sqrt{5}} \Delta^{(k)}.$$

Важно то, что какой бы из отрезков  $[a^{(k)}, b^{(k)}]$  или  $[\alpha^{(k)}, b^{(k)}]$  не был бы выбран за очередной отрезок локализации, точка  $x^{(k+1)}$  (в первом случае  $x^{(k+1)} = \alpha^{(k)}$ , а во втором случае  $x^{(k+1)} = \beta^{(k)}$ ) совпадает с одной из точек  $\alpha^{(k+1)}$ ,  $\beta^{(k+1)}$ . Поэтому на очередном шаге дос-

<sup>1</sup> Термин "золотое сечение" ввел Леонардо да Винчи. Принципы золотого сечения широко использовались при композиционном построении многих произведений мирового искусства (в особенности, архитектурных сооружений античности и эпохи Возрождения).

точно вычислить значение функции лишь в одной недостающей точке.

Заметим, что точка  $x^{(n)}$  отстоит от концов отрезка  $[a^{(n)}, b^{(n)}]$  на величину, не превышающую  $\frac{2}{1 + \sqrt{5}} \Delta^{(n)}$ . Поэтому верна оценка

$$|x^{(n)} - \bar{x}| \leq \frac{2}{1 + \sqrt{5}} \Delta^{(n)} = \Delta^{(n+1)}, \quad (9.12)$$

которую можно использовать для апостериорной оценки погрешности. Заметим, что каждая итерация сокращает длину отрезка локализации в  $(\sqrt{5} + 1)/2$  раз. Поэтому  $b^{(n)} - a^{(n)} = \Delta^{(n)} = (2/(\sqrt{5} + 1))^n \Delta$  и справедлива следующая априорная оценка погрешности:

$$|x^{(n)} - \bar{x}| \leq \left[ \frac{2}{1 + \sqrt{5}} \right]^{n+1} \Delta. \quad (9.13)$$

Таким образом, метод золотого сечения сходится со скоростью геометрической прогрессии, знаменатель которой  $q = 2/(\sqrt{5} + 1) \approx 0.62$ .

**Пример 9.10.** Найдём методом золотого сечения с точностью  $\varepsilon = 10^{-2}$  точку  $\bar{x}$  локального минимума функции  $f(x) = x^3 - x + e^{-x}$ , локализованную на отрезке  $[0, 1]$ .

Положим  $a^{(0)} = 0$ ,  $b^{(0)} = 1$ .

**I итерация.** 1. Вычислим  $\alpha^{(0)} = a^{(0)} + \frac{2}{3 + \sqrt{5}} (b^{(0)} - a^{(0)}) \approx$

$$\approx 0.381966, \quad \beta^{(0)} = a^{(0)} + \frac{2}{1 + \sqrt{5}} (b^{(0)} - a^{(0)}) \approx 0.618034.$$

2. Вычислим  $f(\alpha^{(0)}) \approx 0.356280$ ,  $f(\beta^{(0)}) \approx 0.157037$ .

3. Так как  $f(\alpha^{(0)}) > f(\beta^{(0)})$ , то положим  $[a^{(1)}, b^{(1)}] = [\alpha^{(0)}, \beta^{(0)}]$ .

**II итерация.** 1. Учтем, что  $\alpha^{(1)} = \beta^{(0)} \approx 0.618034$ , и вычислим

$$\beta^{(1)} = a^{(1)} + \frac{2}{1 + \sqrt{5}} (b^{(1)} - a^{(1)}) \approx 0.763936.$$

2. Вычислим  $f(\beta^{(1)}) \approx 0.147725$ .

3. Так как  $f(\alpha^{(1)}) = f(\beta^{(0)}) > f(\beta^{(1)})$ , то положим  $[a^{(2)}, b^{(2)}] = [\alpha^{(1)}, \beta^{(1)}]$ .

Результаты остальных итераций приведены в табл. 9.5.

Т а б л и ц а 9.5

$n$	$a^{(n)}$	$b^{(n)}$	$\alpha^{(n)}$ $f(\alpha^{(n)})$	$\beta^{(n)}$ $f(\beta^{(n)})$	$\Delta^{(n+1)}$
0	0.000000	1.000000	0.381966	0.618034	0.618
			0.356280	0.157037	
1	0.381966	1.000000	0.618034	0.763936	0.382
			0.157037	0.147725	
2	0.618034	1.000000	0.763936	0.854102	0.236
			0.147725	0.194622	
3	0.618034	0.854102	0.708204	0.763936	0.146
			0.139526	0.147725	
4	0.618034	0.763936	0.673764	0.708204	0.090
			0.141883	0.139526	
5	0.673764	0.763936	0.708204	0.729493	0.056
			0.139526	0.140868	
6	0.673764	0.729493	0.695051	0.708204	0.034
			0.139774	0.139526	
7	0.695051	0.729493	0.708204	0.716337	0.021
			0.139526	0.139782	
8	0.695051	0.716337	0.703182	0.708204	0.013
			0.139525	0.139526	
9	0.695051	0.708204			0.008

Так как  $\Delta^{(10)} < \varepsilon$ , то итерации следует прекратить и положить  $\bar{x} \approx \alpha^{(8)} \approx 0.703182$ . Таким образом,  $\bar{x} = 0.70 \pm 0.01$ . Отметим, что для достижения точности  $\varepsilon = 10^{-2}$  потребовалось 10 вычислений значений функции, как и в методе Фибоначчи.

**5. Эффективность методов прямого поиска.** Эффективность указанных методов можно оценивать, например, тем, во сколько раз уменьшается после использования  $N$  вычислений значений функции первоначальная длина  $\Delta$  отрезка локализации. Другой критерий — величина гарантированной оценки погрешности. Табл. 9.6 позволяет сравнить по этим критериям рассмотренные выше методы. Как видно, очень неэффективен пассивный поиск. Метод деления отрезка пополам уступает почти эквивалентным по эффективности методам Фибоначчи и золотого сечения.

Т а б л и ц а 9.6

Метод прямого поиска	Длина отрезка локализации	Величина гарантированной оценки погрешности
Оптимальный пассивный поиск	$\frac{2}{N+1} \Delta$	$\frac{1}{N+1} \Delta$
Метод деления отрезка пополам ( $N$ – четное, величиной $\delta$ пренебрегаем)	$\frac{1}{2^{N/2}} \Delta \approx (0.71)^N \cdot \Delta$	$\approx 0.5 \cdot (0.71)^N \cdot \Delta$
Метод Фибоначчи	$\frac{2}{F_{N+1}} \Delta \approx 1.7 \cdot (0.62)^N \cdot \Delta$	$\approx 0.85 \cdot (0.62)^N \cdot \Delta$
Метод золотого сечения	$\left[ \frac{2}{\sqrt{5}+1} \right]^{N-1} \Delta \approx 1.6 \cdot (0.62)^N \cdot \Delta$	$\approx (0.62)^N \cdot \Delta$

Приведем еще одну таблицу (табл. 9.7), из которой видно, сколько вычислений функции  $f$  нужно сделать для того, чтобы достичь точности  $\epsilon$ . Предполагается, что начальный отрезок локализации имеет единичную длину.

Т а б л и ц а 9.7

Метод прямого поиска	Число $N$ при заданном $\epsilon$				
	$\epsilon = 10^{-1}$	$\epsilon = 10^{-2}$	$\epsilon = 10^{-3}$	$\epsilon = 10^{-4}$	$\epsilon = 10^{-5}$
Оптимальный пассивный поиск	9	99	999	9999	99999
Метод деления отрезка пополам ( $\delta \ll \epsilon$ )	6	12	18	26	32
Метод Фибоначчи	5	10	15	19	24
Метод золотого сечения	5	10	15	20	24

**6. Влияние погрешности вычислений.** Одна из самых распространенных ошибок при обращении к стандартным программам, реализующим тот или иной метод на ЭВМ, состоит в завышении требуемой точности. Необходимо понимать, что при наличии погрешностей в вычислении значений функции  $f$  достижимая точность  $\epsilon$  методов пря-

мого поиска ограничена снизу величиной  $\bar{\epsilon} \approx 2\sqrt{\bar{\Delta}(f^*)/f''(\bar{x})}$ , где  $\bar{\epsilon}$  — радиус интервала неопределенности (см. § 9.2). Это означает, например, что прямые методы не позволяют найти на 6-разрядной десятичной ЭВМ точку  $\bar{x}_2$  локального экстремума функции  $f(x) = x^3 - x + e^{-x}$  с точностью  $\epsilon < \bar{\epsilon}_2 \approx 2 \cdot 10^{-4}$ . Задание  $\epsilon < \bar{\epsilon}_2$  приведет лишь к бесполезной трате машинного времени.

#### § 9.4. Метод Ньютона и другие методы минимизации гладких функций

Отметим, что применение рассмотренных выше методов деления отрезка пополам, Фибоначчи и золотого сечения не позволяет извлечь никакой выгоды из возможной гладкости функции. Существуют методы, которые могут оказаться более эффективными, если минимизируемая функция достаточно гладкая. Часть из них является просто модификациями известных методов решения нелинейных уравнений (см. гл. 4) применительно к уравнению

$$f'(x) = 0. \quad (9.14)$$

**1. Метод бисекции.** Пусть  $f$  — унимодальная непрерывно дифференцируемая на отрезке  $[a^{(0)}, b^{(0)}] = [a, b]$  функция и на отрезке  $[a, b]$  точка  $\bar{x}$  является единственной стационарной точкой. Применительно к решению уравнения (9.14) одна итерация *метода бисекции* выглядит следующим образом.

Пусть отрезок локализации  $[a^{(n)}, b^{(n)}]$  известен и найдено значение  $x^{(n)} = (a^{(n)} + b^{(n)})/2$ . Тогда производят следующие действия.

1°. Вычисляют значение  $f'(x^{(n)})$ .

2°. Если  $f'(x^{(n)}) < 0$ , то полагают  $[a^{(n+1)}, b^{(n+1)}] = [x^{(n)}, b^{(n)}]$ . В противном случае полагают  $[a^{(n+1)}, b^{(n+1)}] = [a^{(n)}, x^{(n)}]$ .

3°. Вычисляют  $x^{(n+1)} = (a^{(n+1)} + b^{(n+1)})/2$ .

В рассматриваемом случае метод сходится с оценкой погрешности

$$|x^{(n)} - \bar{x}| \leq \frac{b - a}{2^{n+1}} \quad (9.15)$$

и обладает всеми присущими методу бисекции решения нелинейных уравнений достоинствами и недостатками (см. § 4.3). Возникает лишь дополнительная проблема, связанная с необходимостью вычисления производной  $f'$ .

**2. Метод Ньютона.** Для решения уравнения (9.14) можно попытаться воспользоваться методом Ньютона (см. § 4.6), расчетная формула которого в данном случае принимает вид

$$x^{(n+1)} = x^{(n)} - \frac{f'(x^{(n)})}{f''(x^{(n)})}, \quad n \geq 0. \quad (9.16)$$

Следствием теоремы 4.6 является следующее утверждение.

**Теорема 9.1.** Пусть в некоторой окрестности точки  $\bar{x}$  функция  $f$  трижды непрерывно дифференцируема и выполняется условие  $f''(\bar{x}) > 0$ . Тогда найдется такая малая  $\sigma$ -окрестность корня  $\bar{x}$ , что при произвольном выборе начального приближения  $x^{(0)}$  из этой  $\sigma$ -окрестности метод Ньютона (9.16) сходится квадратично.

В силу сверхлинейной сходимости для метода Ньютона можно использовать следующий критерий окончания итераций:

$$|x^{(n)} - x^{(n-1)}| < \varepsilon. \quad (9.17)$$

**Пример 9.11.** Используя метод бисекции, найдем с точностью  $\varepsilon = 10^{-2}$  точку локального минимума функции  $f(x) = x^3 - x + e^{-x}$ , локализованную на отрезке  $[0, 1]$ .

Положим  $a^{(0)} = 0$ ,  $b^{(0)} = 1$ ,  $x^{(0)} = (a^{(0)} + b^{(0)})/2 = 0.5$ . Заметим, что  $f'(x) = 3x^2 - 1 - e^{-x}$ .

**И т е р а ц и я.** 1. Вычислим  $f'(x^{(0)}) \approx -0.856531$ .

2. Так как  $f'(x^{(0)}) < 0$ , то  $[a^{(1)}, b^{(1)}] = [x^{(0)}, b^{(0)}]$ .

3. Вычислим  $x^{(1)} = (a^{(1)} + b^{(1)})/2 = 0.75$ .

Результаты остальных итераций приведены в табл. 9.8.

Т а б л и ц а 9.8

$n$	$a^{(n)}$	$b^{(n)}$	$x^{(n)}$	$f'(x^{(n)})$	$(b^{(n)} - a^{(n)})/2$
0	0.000000	1.000000	0.500000	-0.856531	0.500
1	0.500000	1.000000	0.750000	0.215133	0.250
2	0.500000	0.750000	0.625000	-0.363386	0.125
3	0.625000	0.750000	0.687500	-0.084863	0.063
4	0.687500	0.750000	0.718750	0.062444	0.031
5	0.687500	0.718750	0.703125	-0.011882	0.016
6	0.703125	0.718750	0.710938		0.008

После выполнения шести итераций вычисления можно прекратить и положить  $\bar{x} \approx x^{(6)}$ . Таким образом,  $\bar{x} = 0.71 \pm 0.01$ . Отметим, что для достижения точности  $\varepsilon = 10^{-2}$  потребовалось шесть вычислений значения производной  $f'(x)$ .

**Пример 9.12.** Используя метод Ньютона, найдем с точностью  $\epsilon = 10^{-6}$  точку локального минимума функции  $f(x) = x^3 - x + e^{-x}$ , локализованную на отрезке  $[0, 1]$ .

Положим  $x^{(0)} = 0.5$ . Результаты вычислений по формуле (9.16), имеющей в данном случае вид

$$x^{(n+1)} = x^{(n)} - \frac{3(x^{(n)})^2 - 1 - e^{-x^{(n)}}}{6x^{(n)} + e^{-x^{(n)}}},$$

приведены в табл. 9.9.

Т а б л и ц а 9.9

$n$	$x^{(n)}$	$ x^{(n)} - x^{(n-1)} $
0	0.5000000	
1	0.7374944	$2 \cdot 10^{-1}$
2	0.7062126	$3 \cdot 10^{-2}$
3	0.7056421	$6 \cdot 10^{-4}$
4	0.7056419	$2 \cdot 10^{-7}$

При  $n = 4$  итерации прерываются. Можно считать, что  $\bar{x} = 0.705642 \pm 10^{-6}$ . Заметим, что точность  $\epsilon = 10^{-2}$  была достигнута уже после выполнения двух итераций.

**3. Метод последовательной параболической интерполяции.** Этот метод предназначен для минимизации гладких функций, но в отличие от методов бисекции и Ньютона не требует вычисления производных.

Опишем одну итерацию простейшего варианта этого метода. Предположим, что уже известны три предыдущих приближения  $x^{(k-2)}$ ,  $x^{(k-1)}$ ,  $x^{(k)}$  к точке  $\bar{x}$ . Пусть  $y = P_2(x) = m^{(k)} + n^{(k)}(x - x^{(k)}) + p^{(k)}(x - x^{(k)})^2$  — уравнение параболы, проходящей через три точки плоскости с координатами  $(x^{(k-2)}, f(x^{(k-2)}))$ ,  $(x^{(k-1)}, f(x^{(k-1)}))$ ,  $(x^{(k)}, f(x^{(k)}))$ . Здесь

$$m^{(k)} = f(x^{(k)}), \quad n^{(k)} = \frac{x^{(k-1)} - x^{(k)}}{x^{(k-1)} - x^{(k-2)}} \cdot \frac{f(x^{(k)}) - f(x^{(k-2)})}{x^{(k)} - x^{(k-2)}} + \\ + \frac{x^{(k)} - x^{(k-2)}}{x^{(k-1)} - x^{(k-2)}} \cdot \frac{f(x^{(k-1)}) - f(x^{(k)})}{x^{(k-1)} - x^{(k)}},$$

$$p^{(k)} = \frac{1}{x^{(k-1)} - x^{(k-2)}} \cdot \left[ \frac{f(x^{(k-1)}) - f(x^{(k)})}{x^{(k-1)} - x^{(k)}} - \frac{f(x^{(k)}) - f(x^{(k-2)})}{x^{(k)} - x^{(k-2)}} \right].$$



За очередное приближение  $x^{(k+1)}$  к  $\bar{x}$  принимается та точка, в которой функция  $P_2(x)$  достигает минимума. Из уравнения

$$P_2'(x^{(k+1)}) = 2p^{(k)}(x^{(k+1)} - x^{(k)}) + n^{(k)} = 0$$

получается формула

$$x^{(k+1)} = x^{(k)} - \frac{n^{(k)}}{2p^{(k)}}. \quad (9.18)$$

Естественно, что для начала работы этого метода требуется выбор трех начальных приближений  $x^{(0)}, x^{(1)}, x^{(2)}$ .

Пусть функция  $f$  трижды непрерывно дифференцируема в некоторой окрестности точки  $\bar{x}$  и удовлетворяет в ней условию  $f''(\bar{x}) > 0$ . Можно показать, что в этом случае выбор начальных приближений  $x^{(0)}, x^{(1)}, x^{(2)}$  из достаточно малой окрестности точки  $\bar{x}$  гарантирует, что  $p^{(k)} \neq 0$  для всех  $k$  и метод последовательной параболической интерполяции сходится сверхлинейно, с порядком, приближенно равным 1.324. Поэтому в качестве критерия окончания итерационного процесса можно принять неравенство (9.17).

Отметим, что в описанном методе используются только значения функции  $f$ , вычисляемые в точках  $x^{(k)}$ . Поэтому (как и для методов прямого поиска) при его реализации на ЭВМ достижимая точность метода ограничена снизу величиной, равной радиусу  $\bar{\epsilon}$  интервала неопределенности. После того как очередное приближение  $x^{(n)}$  попадет в интервал  $(\bar{x} - \bar{\epsilon}, \bar{x} + \bar{\epsilon})$ , дальнейшие вычисления теряют смысл (см. § 9.2).

Существуют различные модификации метода последовательной параболической интерполяции. Одна из них, например, обеспечивает принадлежность очередного приближения предыдущему отрезку локализации и дает последовательность стягивающихся к точке  $\bar{x}$  отрезков.

**4. Гибридные алгоритмы.** Лучшими среди универсальных методов одномерной минимизации считаются так называемые *гибридные* (или *регуляризованные*) алгоритмы. Они представляют собой комбинации надежных, но медленно сходящихся алгоритмов типа бисекции (если возможно вычисление  $f'(x)$ ) или золотого сечения с быстро сходящимися методами типа последовательной параболической интерполяции или Ньютона. Эти алгоритмы обладают высокой надежностью и гарантированной сходимостью, причем сходимость становится сверхлинейной, если в окрестности точки строгого минимума функция  $f(x)$  достаточно гладкая.

Примером эффективного гибридного алгоритма является алгоритм FMIN, изложенный в [86]. Алгоритм FMIN осуществляет поиск минимума методом золотого сечения, переключаясь по возможности на параболическую интерполяцию.

### § 9.5. Дополнительные замечания

1. Дополнительную информацию о методах одномерной минимизации можно найти, например, в пособии [18].

2. Описанные выше методы приспособлены, как правило, для минимизации унимодальных функций. Если эти методы применить для минимизации непрерывной функции, не являющейся унимодальной на рассматриваемом отрезке, то мы получим, вообще говоря, лишь точку локального экстремума. Поэтому такие методы часто называют локальными методами минимизации. К настоящему времени разработан ряд методов, которые предназначены для поиска глобального минимума. С некоторыми из них можно ознакомиться в [18].

3. Решение задачи минимизации существенно усложняется, если на значения функции накладываются случайные ошибки (помехи). Так бывает, например, тогда, когда значения функции получают в результате измерений какой-либо физической величины. В том случае, когда ошибки являются случайными величинами и обладают определенными вероятностными характеристиками, для поиска минимума можно использовать *метод стохастической аппроксимации*. Понятие об этом методе можно получить из [18]; там же содержатся ссылки на соответствующую литературу.

## Глава 10

### МЕТОДЫ МНОГОМЕРНОЙ МИНИМИЗАЦИИ

Одной из наиболее часто встречающихся в инженерных расчетах и научных исследованиях вычислительных задач является задача минимизации<sup>1</sup> функции  $m$  действительных переменных  $f(x_1, x_2, \dots, x_m)$ . Функция  $f$  (*целевая функция*) минимизируется на некотором множестве  $X \subset R^m$ . В случае, когда  $X = R^m$  (т. е. ограничения на переменные  $x_1, x_2, \dots, x_m$  отсутствуют) принято говорить о задаче *безусловной минимизации*. В противном случае (т. е. тогда, когда  $X \neq R^m$ ) говорят о задаче *условной минимизации*.

В данной главе рассматриваются методы решения задачи безусловной минимизации. Многие из них являются основой для перехода к более сложным методам решения задач условной минимизации.

#### § 10.1. Задача безусловной минимизации функции многих переменных

**1. Постановка задачи. Определения.** Пусть  $f(\mathbf{x}) = f(x_1, x_2, \dots, x_m)$  — действительная функция многих переменных, определенная на множестве  $X \subset R^m$ . Точка  $\bar{\mathbf{x}} \in X$  называется *точкой глобального минимума* функции  $f$  на множестве  $X$ , если для всех  $\mathbf{x} \in X$  выполняется неравенство  $f(\bar{\mathbf{x}}) \leq f(\mathbf{x})$ . В этом случае значение  $f(\bar{\mathbf{x}})$  называется *минимальным значением функции  $f$  на  $X$* .

Точка  $\bar{\mathbf{x}} \in X$  называется *точкой локального минимума* функции  $f$ , если существует такая  $\delta$ -окрестность  $U_\delta$  этой точки, что для всех

---

<sup>1</sup> Как и в случае одной переменной, задача максимизации сводится к задаче минимизации заменой функции  $f$  на  $-f$ .

$\mathbf{x} \in X_\delta = X \cap U_\delta$  выполняется неравенство  $f(\bar{\mathbf{x}}) \leq f(\mathbf{x})$ . Если же для всех  $\mathbf{x} \in X_\delta$  ( $\mathbf{x} \neq \bar{\mathbf{x}}$ ) выполняется строгое неравенство  $f(\bar{\mathbf{x}}) < f(\mathbf{x})$ , то  $\bar{\mathbf{x}}$  называется *точкой строгого локального минимума*.

Подавляющее большинство методов решения задачи безусловной минимизации в действительности являются методами поиска точки локального минимума. За исключением весьма редких случаев для нахождения точки глобального минимума, вообще говоря, не остается ничего иного, как найти все точки локального минимума и, сравнивая вычисленные в этих точках значения функции  $f$ , выделить среди них точку глобального минимума. Однако такой подход связан с чрезмерно большими вычислительными затратами и вряд ли перспективен. На практике чаще используется другой подход к нахождению точки глобального минимума, который состоит в том, чтобы определить ее местоположение из анализа самой решаемой задачи, а затем применить для вычисления один из методов поиска точки локального минимума.

**2. Поверхность уровня, градиент и матрица Гессе. Необходимые и достаточные условия локального минимума.** Напомним некоторые определения и факты, известные из стандартного курса теории функций многих переменных.

Множество точек, для которых целевая функция принимает постоянное значение  $f(\mathbf{x}) = c$ , называется *поверхностью уровня*. В случае  $m = 2$  это множество называют *линией уровня*. На рис. 10.1 показано, как получаются линии уровня для функции двух переменных. Функция  $f(x_1, x_2)$  задает в трехмерном пространстве некоторую поверхность  $u = f(x_1, x_2)$ , низшая точка которой и дает решение задачи минимизации. Для того чтобы изобразить рельеф этой поверхности, проведем несколько равноотстоящих плоскостей  $u = \text{const}$ . Проекция на плоскость  $Ox_1x_2$  линий пересечения этих плоскостей с поверхностью и дают линии уровня.

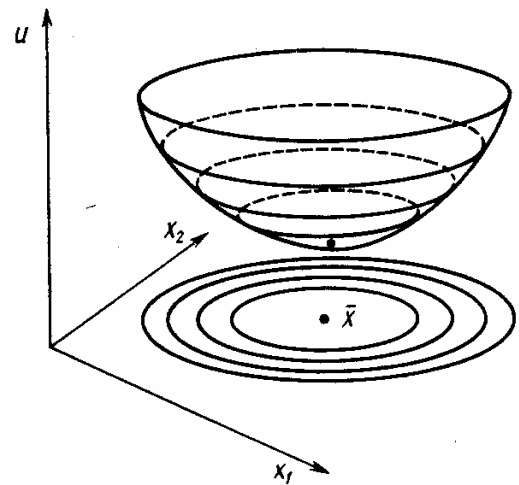


Рис. 10.1

Для дифференцируемой функции определен вектор из первых частных производных

$$\mathbf{g}(\mathbf{x}) = f'(\mathbf{x}) = \left[ \frac{\partial f}{\partial x_1}(\mathbf{x}), \frac{\partial f}{\partial x_2}(\mathbf{x}), \dots, \frac{\partial f}{\partial x_m}(\mathbf{x}) \right]^T,$$

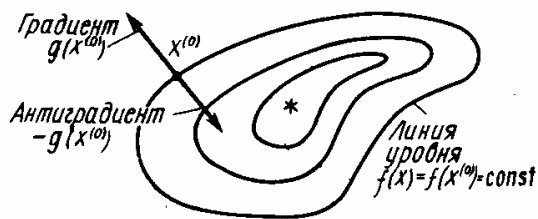


Рис. 10.2

который называется *градиентом*. Если в точке  $\mathbf{x}$  градиент не равен нулю, то он, как известно, перпендикулярен проходящей через эту точку поверхности уровня и указывает в точке  $\mathbf{x}$  направление наискорейшего возрастания функции. Вектор  $-\mathbf{g}(\mathbf{x})$  называется

*антиградиентом* и указывает направление наискорейшего убывания функции (рис. 10.2).

Известно также, что равенство нулю градиента в точке  $\mathbf{x}$  является необходимым условием того, чтобы внутренняя для множества  $X$  точка  $\mathbf{x}$  была точкой локального минимума дифференцируемой функции  $f$ . Точка  $\mathbf{x}$ , для которой выполняется равенство

$$f'(\mathbf{x}) = 0, \quad (10.1)$$

называется *стационарной точкой* функции  $f$ . Равенство (10.1) представляет собой систему  $m$  нелинейных уравнений относительно компонент  $x_1, x_2, \dots, x_m$  вектора  $\mathbf{x}$ , имеющую вид

$$\begin{aligned} \frac{\partial f}{\partial x_1} (x_1, x_2, \dots, x_m) &= 0, \\ &\dots \dots \dots \\ \frac{\partial f}{\partial x_m} (x_1, x_2, \dots, x_m) &= 0. \end{aligned} \quad (10.2)$$

Однако не всякая стационарная точка является точкой локального минимума. Пусть функция  $f$  дважды непрерывно дифференцируема. Тогда достаточным условием того, чтобы стационарная точка  $\mathbf{x}$  была точкой локального минимума, является положительная определенность<sup>1</sup> матрицы

$$G(\mathbf{x}) = f''(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2}(\mathbf{x}) & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_m}(\mathbf{x}) \\ \dots & \dots & \dots \\ \frac{\partial^2 f}{\partial x_m \partial x_1}(\mathbf{x}) & \dots & \frac{\partial^2 f}{\partial x_m^2}(\mathbf{x}) \end{bmatrix}, \quad (10.3)$$

<sup>1</sup> Определение положительно определенной симметричной матрицы см. в § 5.3.

составленной из вторых частных производных функции  $f$ . Матрицу (10.3) принято называть *матрицей Гессе*<sup>1</sup>.

**3. Выпуклые функции.** Понятие выпуклости играет значительную роль в теории методов минимизации. Функция  $f$  называется *строго выпуклой*, если для любых  $x \neq y$ ,  $0 < \lambda < 1$  выполняется неравенство

$$f(\lambda x + (1 - \lambda)y) < \lambda f(x) + (1 - \lambda)f(y).$$

Это определение имеет наглядный геометрический смысл — график функции  $f$  на интервале, соединяющем точки  $x$  и  $y$ , лежит строго ниже хорды, проходящей через точки  $(x, f(x))$  и  $(y, f(y))$  (рис. 10.3). Для дважды непрерывно дифференцируемой функции положительная определенность матрицы Гессе  $f''(x)$  является достаточным условием строгой выпуклости.

Функция  $f$  называется *сильно выпуклой* с постоянной  $\alpha > 0$ , если для любых  $x, y$ ,  $0 < \lambda < 1$  выполнено неравенство

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y) - \frac{\alpha}{2} \lambda(1 - \lambda)|x - y|^2. \quad (10.4)$$

Дважды непрерывно дифференцируемая функция  $f$  является сильно выпуклой тогда и только тогда, когда для всех  $x$  матрица Гессе удовлетворяет условию

$$(f''(x)\xi, \xi) \geq \alpha |\xi|^2, \quad \xi \in R^m,$$

где  $\alpha > 0$  — постоянная, входящая в неравенство (10.4).

**4. Задача минимизации квадратичной функции.** Часто первоначальное исследование свойств методов безусловной минимизации проводится применительно к задаче минимизации квадратичной функции

$$F(x_1, x_2, \dots, x_m) = \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j - \sum_{i=1}^m b_i x_i, \quad (10.5)$$

коэффициенты  $a_{ij}$  которой являются элементами симметричной положительно определенной матрицы  $A$ . Используя матричные обозначения, запишем функцию  $F$  так:

<sup>1</sup> Людвиг Отто Гессе (1811—1874) — немецкий математик.

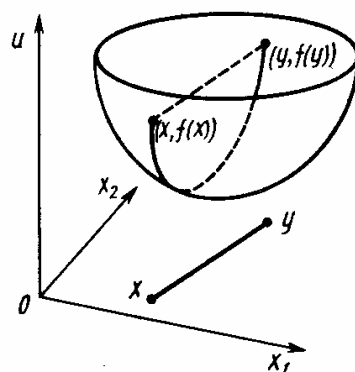


Рис. 10.3

$$F(\mathbf{x}) = \frac{1}{2} (\mathbf{Ax}, \mathbf{x}) - (\mathbf{b}, \mathbf{x}). \quad (10.6)$$

Вычислим градиент и матрицу Гессе для функции (10.5). Дифференцирование  $F$  по  $x_k$  дает

$$\frac{\partial F}{\partial x_k} = \frac{1}{2} \sum_{j=1}^m a_{kj} x_j + \frac{1}{2} \sum_{i=1}^m a_{ik} x_i - b_k.$$

Пользуясь симметрией матрицы  $A$ , получим формулу

$$\frac{\partial F}{\partial x_k} = \sum_{j=1}^m a_{kj} x_j - b_k. \quad (10.7)$$

Таким образом,

$$F'(\mathbf{x}) = \mathbf{Ax} - \mathbf{b}. \quad (10.8)$$

Дифференцируя обе части равенства (10.7) по  $x_l$ , получим  $\frac{\partial^2 F}{\partial x_l \partial x_k} = a_{lk}$ . Это означает, что для квадратичной функции (10.5) матрица Гессе не зависит от  $\mathbf{x}$  и равна  $A$ .

Задача минимизации квадратичной функции представляет интерес по многим причинам. Отметим две основные из них. Во-первых, в малой окрестности точки минимума гладкая целевая функция хорошо аппроксимируется суммой первых трех слагаемых ее разложения по формуле Тейлора:

$$f(\mathbf{x}) \approx F_*(\mathbf{x}) = f(\mathbf{x}^*) + (\mathbf{g}(\mathbf{x}^*), \mathbf{x} - \mathbf{x}^*) + \frac{1}{2} (\mathbf{G}(\mathbf{x}^*)(\mathbf{x} - \mathbf{x}^*), \mathbf{x} - \mathbf{x}^*) \quad (10.9)$$

с центром в точке  $\mathbf{x}^* \approx \bar{\mathbf{x}}$ . Функция  $F_*$  с точностью до постоянного слагаемого может быть записана в виде (10.6) с матрицей  $A = \mathbf{G}(\mathbf{x}^*) \approx \mathbf{G}(\bar{\mathbf{x}})$ . Поэтому можно ожидать, что вблизи точки минимума качественный характер поведения последовательности  $\mathbf{x}^{(n)}$ , генерируемой методом минимизации, для функции  $f$  окажется почти таким же, как и для квадратичной функции  $F$ .

Во-вторых, хорошо известно, что в случае, когда  $A$  — симметричная положительно определенная матрица, задача минимизации квадратичной функции (10.6) эквивалентна задаче решения системы линейных алгебраических уравнений

$$\mathbf{Ax} = \mathbf{b}. \quad (10.10)$$

Более того, решение  $\mathbf{x}^0$  системы (10.10) дает точку минимума функции

(10.6). Действительно,  $F'(\mathbf{x}^0) = A\mathbf{x}^0 - \mathbf{b} = 0$ , т. е.  $\mathbf{x}^0$  является стационарной точкой функции  $F$ . Так как матрица Гессе  $F''(\mathbf{x}^0) = A$  положительно определена, то в точке  $\mathbf{x}^0$  выполнены достаточные условия минимума и, значит,  $\mathbf{x}^0 = \bar{\mathbf{x}}$ .

Таким образом, всякий метод безусловной минимизации, будучи примененным к поиску минимума функции (10.6), порождает некоторый метод решения системы (10.10).

Отметим, что поверхностями уровня квадратичной функции (10.6) служат  $m$ -мерные эллипсоиды (при  $m = 2$  — эллипсы) с центром в точке  $\bar{\mathbf{x}}$ . Отношение большей оси каждого из этих эллипсоидов (эллипсов) к меньшей оси равно  $\text{cond}_2(A) = \lambda_{\max}/\lambda_{\min}$  — числу обусловленности матрицы  $A$ . Здесь  $\lambda_{\max}$  и  $\lambda_{\min}$  — максимальное и минимальное собственные значения матрицы  $A$ . Чем больше отношение  $\lambda_{\max}/\lambda_{\min}$ , тем сильнее вытянуты поверхности (линии) уровня.

**5. Обусловленность задачи минимизации.** В § 9.2 достаточно подробно обсуждалась обусловленность задачи поиска строгого локального минимума функции одной переменной. Так как ситуация в многомерном случае аналогична, то здесь изложим соответствующие положения более кратко.

Пусть  $\bar{\mathbf{x}}$  — точка строго локального минимума дважды непрерывно дифференцируемой функции  $f$ , матрица Гессе которой в точке  $\bar{\mathbf{x}}$  положительно определена. Предположим, что в некоторой окрестности точки минимума вычисляемые приближенные значения  $f^*(\mathbf{x})$  удовлетворяют неравенству  $|f(\mathbf{x}) - f^*(\mathbf{x})| \leq \bar{\Delta} = \bar{\Delta}(f^*)$ . Тогда для радиуса соответствующей области неопределенности справедлива грубая оценка  $\bar{\epsilon} \approx 2 \sqrt{\bar{\Delta}/\lambda_{\min}}$ , где  $\lambda_{\min} > 0$  — минимальное собственное значение матрицы Гессе  $f''(\bar{\mathbf{x}})$ .

Отсюда следует, что методы приближенного решения задачи минимизации, в которых используются только значения  $f^*$ , не могут, вообще говоря, гарантировать получение приближенного решения  $\bar{\mathbf{x}}^*$  с погрешностью меньшей чем  $\bar{\Delta}(\bar{\mathbf{x}}^*) \approx 2 \sqrt{\bar{\Delta}/\lambda_{\min}}$ . Это означает, например, что даже для хорошо масштабированных задач (т. е. при  $|\bar{\mathbf{x}}| \sim 1$ ,  $|f(\bar{\mathbf{x}})| \sim 1$ ,  $\lambda_{\min} \sim 1$ ) неизбежна потеря примерно половины из того числа верных значащих цифр, которые содержались в приближенных значениях  $f^*(\mathbf{x})$ .

Пусть теперь для решения задачи минимизации доступны приб-



лиженные значения градиента  $(f')^*$ . Тогда сведение задачи поиска точки минимума  $\bar{x}$  к эквивалентной задаче решения системы уравнений  $f'(x) = 0$  существенно улучшает обусловленность задачи. В частности, справедлива такая оценка границы абсолютной погрешности:

$$\bar{\Delta}(\bar{x}^*) \approx \frac{1}{\lambda_{\min}} \bar{\Delta}((f')^*).$$

Здесь  $\bar{\Delta}((f')^*)$  — граница абсолютной погрешности значений  $(f')^*$ , считающаяся достаточно малой величиной. Поэтому если для вычисления  $\bar{x}$  можно использовать значения градиента, то такой возможностью не следует пренебрегать.

## § 10.2. Понятие о методах спуска.

### Покоординатный спуск

**1. Методы спуска.** Большинство итерационных методов, применяемых для решения задачи безусловной минимизации функций многих переменных, относятся к классу *методов спуска*, т. е. таких методов, для которых каждая итерация (шаг) приводит к уменьшению значения целевой функции:  $f(x^{(n+1)}) < f(x^{(n)})$  для всех  $n \geq 0$ .

Опишем структуру типичной  $(n + 1)$ -й итерации метода спуска в предположении, что приближение  $x^{(n)}$  к точке минимума уже найдено и  $x^{(n)} \neq \bar{x}$ .

1°. Находят ненулевой вектор  $p^{(n)}$ , называемый *направлением спуска*. Этот вектор должен быть таким, чтобы при всех достаточно малых  $\alpha > 0$  выполнялось неравенство

$$f(x^{(n)} + \alpha p^{(n)}) < f(x^{(n)}). \quad (10.11)$$

Если ввести функцию одной переменной  $\alpha$ , имеющую вид

$$\varphi_n(\alpha) = f(x^{(n)} + \alpha p^{(n)}), \quad (10.12)$$

то неравенство (10.11) можно записать так:  $\varphi_n(\alpha) < \varphi_n(0)$ .

2°. Вычисляют положительное число  $\alpha_n$  (*шаг спуска*), для которого выполняется неравенство

$$f(x^{(n)} + \alpha_n p^{(n)}) < f(x^{(n)}), \quad (10.13)$$

или, что то же самое, неравенство  $\varphi_n(\alpha_n) < \varphi_n(0)$ .

3°. За очередное приближение к точке минимума принимают

$$\mathbf{x}^{(n+1)} = \mathbf{x}^{(n)} + \alpha_n \mathbf{p}^{(n)}.$$

4°. Проверяют выполнение критерия окончания итераций. Если критерий выполняется, то итерации прекращают и полагают  $\bar{\mathbf{x}} \approx \mathbf{x}^{(n+1)}$ . В противном случае итерации продолжают далее.

Последовательность точек  $\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \dots, \mathbf{x}^{(n)}, \dots$ , генерируемую методом спуска, иногда называют *траекторией спуска*.

**2. Направление спуска.** Заметим, что вектор  $\mathbf{p}^{(n)}$  не может быть задан произвольно. В силу требования (10.11) функция  $\varphi_n(\alpha)$ , определяемая формулой (10.12), должна убывать в точке  $\alpha = 0$ . Для того чтобы это условие выполнялось, достаточно потребовать выполнения неравенства  $\varphi'_n(0) < 0$ . Так как  $\varphi'_n(\alpha) = (f'(\mathbf{x}^{(n)} + \alpha \mathbf{p}^{(n)}), \mathbf{p}^{(n)})$ , то вектор  $\mathbf{p}^{(n)}$  является направлением спуска, т. е. удовлетворяет условию (10.11), если

$$(f'(\mathbf{x}^{(n)}), \mathbf{p}^{(n)}) < 0. \quad (10.14)$$

Можно показать, что для строго выпуклой функции  $f$  это неравенство выполняется тогда и только тогда, когда вектор  $\mathbf{p}^{(n)}$  задает направление спуска.

Обычно именно способ выбора направления спуска  $\mathbf{p}^{(n)}$  определяет конкретный численный метод, а различные варианты метода определяются далее алгоритмом вычисления шага спуска  $\alpha_n$ . Например, выбор в качестве  $\mathbf{p}^{(n)}$  антиградиента  $\mathbf{p}^{(n)} = -f'(\mathbf{x}^{(n)})$  задает градиентный метод (см. § 10.3). В этом случае  $(f'(\mathbf{x}^{(n)}), \mathbf{p}^{(n)}) = -|f'(\mathbf{x}^{(n)})|^2 < 0$ , т. е. условие (10.14) выполняется.

**3. Выбор шага спуска.** Следует иметь в виду, что шаг  $\alpha_n$  спуска определяет "истинную" величину шага  $h_n = |\mathbf{x}^{(n+1)} - \mathbf{x}^{(n)}| = \alpha_n |\mathbf{p}^{(n)}|$ , но совпадает с ней только тогда, когда вектор  $\mathbf{p}^{(n)}$  имеет единичную длину.

В качестве  $\alpha_n$  можно выбирать значение параметра  $\alpha$ , которое обеспечивает достижение наименьшего значения функции  $f$  вдоль луча  $\mathbf{x} = \mathbf{x}^{(n)} + \alpha \mathbf{p}^{(n)}$ ,  $\alpha \geq 0$ . В этом случае для вычисления  $\alpha_n$  требуется решение одномерной задачи минимизации функции  $\varphi_n(\alpha)$ . Этот путь достаточно надежен, однако может быть связан с большими вычислительными затратами.

Существуют и активно применяются другие подходы к выбору  $\alpha_n$ , гарантирующие выполнение условия (10.13). Один из простейших подходов, называемый *дроблением шага*, состоит в следующем. Фиксируют начальное значение шага  $\alpha$  и выбирают параметр  $\gamma$ ,  $0 < \gamma < 1$

(часто  $\gamma = 1/2$ ). За шаг спуска принимают  $\alpha_n = \alpha \cdot \gamma^{i_n}$ , где  $i_n$  — первый из номеров  $i = 0, 1, 2, \dots$ , для которого выполнено условие

$$f(\mathbf{x}^{(n)} + \alpha \cdot \gamma^{i_n} \mathbf{p}^{(n)}) - f(\mathbf{x}^{(n)}) \leq \beta \cdot \alpha \cdot \gamma^{i_n} (f'(\mathbf{x}^{(n)}), \mathbf{p}^{(n)}). \quad (10.15)$$

Здесь  $0 < \beta < 1$ ,  $\beta$  — некоторый дополнительный параметр.

**4. Критерии окончания итераций.** На практике часто используют следующие критерии окончания итераций:

$$|\mathbf{x}^{(n+1)} - \mathbf{x}^{(n)}| < \varepsilon_1, \quad (10.16)$$

$$|f(\mathbf{x}^{(n+1)}) - f(\mathbf{x}^{(n)})| < \varepsilon_2, \quad (10.17)$$

$$|f'(\mathbf{x}^{(n)})| < \varepsilon_3, \quad (10.18)$$

где  $\varepsilon_1, \varepsilon_2, \varepsilon_3$  — заданные положительные числа. Нередко используют различные их сочетания, например требуют, чтобы одновременно выполнялись условия (10.16) и (10.17) или даже все три условия (10.16)—(10.18).

Нередко вместо критериев (10.16), (10.17) применяют их аналоги, основанные на сочетании понятий относительной и абсолютной погрешностей:

$$|\mathbf{x}^{(n+1)} - \mathbf{x}^{(n)}| < \delta_1(1 + |\mathbf{x}^{(n+1)}|), \quad (10.19)$$

$$|f(\mathbf{x}^{(n+1)}) - f(\mathbf{x}^{(n)})| < \delta_2(1 + |f(\mathbf{x}^{(n+1)})|), \quad (10.20)$$

а также другие критерии.

К сожалению, надежные критерии окончания счета, которые были бы применимы к широкому классу задач и гарантировали бы достижение нужной точности, пока не известны.

**5. Покоординатный спуск.** В методе покоординатного спуска в качестве очередного направления спуска выбирают направление одной из координатных осей. Наиболее известным является *метод циклического покоординатного спуска*. Опишем очередной  $(n + 1)$ -й цикл одного из вариантов этого метода, считая приближение  $\mathbf{x}^{(n)}$  уже найденным.

Цикл с номером  $n + 1$  состоит из  $m$  шагов. На первом шаге производят спуск по координате  $x_1$ . Значения  $x_2 = x_2^{(n)}, \dots, x_m = x_m^{(n)}$  остальных координат фиксируют, а  $x_1^{(n+1)}$  выбирают из условия

$$f(x_1^{(n+1)}, x_2^{(n)}, \dots, x_m^{(n)}) = \min_{x_1} f(x_1, x_2^{(n)}, \dots, x_m^{(n)}).$$

Фактически решается задача минимизации функции одной переменной

$$f_1(x_1) = f(x_1, x_2^{(n)}, \dots, x_m^{(n)}).$$

На втором шаге производят спуск по координате  $x_2$ . Значения  $x_1 = x_1^{(n+1)}$ ,  $x_3 = x_3^{(n)}$ , ...,  $x_m = x_m^{(n)}$  остальных координат фиксируют и  $x_2^{(n+1)}$  выбирают как решение задачи одномерной минимизации

$$f(x_1^{(n+1)}, x_2^{(n+1)}, x_3^{(n)}, \dots, x_m^{(n)}) = \min_{x_2} f(x_1^{(n+1)}, x_2, x_3^{(n)}, \dots, x_m^{(n)}).$$

Аналогично осуществляют остальные шаги. На последнем  $m$ -м шаге координату  $x_m^{(n+1)}$  определяют из условия

$$f(x_1^{(n+1)}, \dots, x_{m-1}^{(n+1)}, x_m^{(n+1)}) = \min_{x_m} f(x_1^{(n+1)}, \dots, x_{m-1}^{(n+1)}, x_m).$$

В результате получается очередное приближение  $x^{(n+1)}$  к точке минимума. Далее цикл метода снова повторяют.

На рис. 10.4 изображена геометрическая иллюстрация циклического покоординатного спуска.

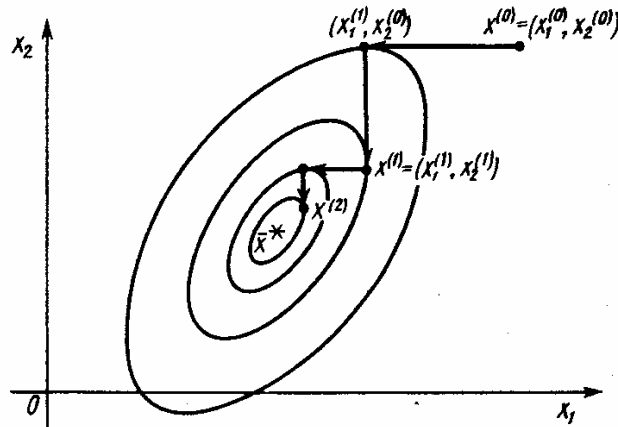


Рис. 10.4

• Применим метод циклического покоординатного спуска для минимизации квадратичной функции (10.5). Так как на  $k$ -м шаге очередного цикла значение координаты  $x_k^{(n+1)}$  определяется из условия минимизации функции  $F$  по направлению  $x_k$ , то необходимо, чтобы в точке  $(x_1^{(n+1)}, \dots, x_{k-1}^{(n+1)}, x_k^{(n+1)}, x_{k+1}^{(n)}, \dots, x_m^{(n)})^T$  производная  $\partial F / \partial x_k$  обращалась в нуль. Учитывая формулу (10.7), получаем уравнение

$$\sum_{j=1}^k a_{kj} x_j^{(n+1)} + \sum_{j=k+1}^m a_{kj} x_j^{(n)} - b_k = 0,$$

откуда находим

$$x_k^{(n+1)} = a_{kk}^{-1} \left( b_k - \sum_{j=1}^{k-1} a_{kj} x_j^{(n+1)} - \sum_{j=k+1}^m a_{kj} x_j^{(n)} \right). \quad (10.21)$$

Последовательные вычисления по формуле (10.21) для  $k = 1, 2, \dots, m$  и составляют один цикл метода покоординатного спуска. Заметим, что этот метод применительно к решению системы линейных алгебраических уравнений  $Ax = b$  с симметричной положительно определенной матрицей дает известный итерационный метод Зейделя (см. гл. 6), сходящийся со скоростью геометрической прогрессии.

### § 10.3. Градиентный метод

Рассмотрим задачу безусловной минимизации дифференцируемой функции многих переменных  $f(x)$ . Пусть  $x^{(n)}$  — приближение к точке минимума  $\bar{x}$ , а  $g^{(n)} = g(x^{(n)})$  — значение градиента в точке  $x^{(n)}$ . Выше уже отмечалось, что в малой окрестности точки  $x^{(n)}$  направление наискорейшего убывания функции  $f$  задается антиградиентом  $-g^{(n)}$ . Это свойство существенно используется в ряде методов минимизации. В рассматриваемом ниже *градиентном методе* за направление спуска из точки  $x^{(n)}$  непосредственно выбирается  $p^{(n)} = -g^{(n)}$ . Таким образом, согласно градиентному методу

$$x^{(n+1)} = x^{(n)} - \alpha_n g^{(n)}. \quad (10.22)$$

Существуют различные способы выбора шага  $\alpha_n$ , каждый из которых задает определенный вариант градиентного метода.

**1. Метод наискорейшего спуска.** Рассмотрим функцию  $\varphi_n(\alpha) = f(x^{(n)} - \alpha g^{(n)})$  одной скалярной переменной  $\alpha \geq 0$  и выберем в качестве  $\alpha_n$  то значение, для которого выполняется равенство

$$\varphi_n(\alpha_n) = \min_{0 < \alpha} \varphi_n(\alpha). \quad (10.23)$$

Этот метод, предложенный в 1845 г. О. Коши<sup>1</sup>, принято теперь называть *методом наискорейшего спуска*.

---

<sup>1</sup> Огюстен Луи Коши (1789—1857) — французский математик, один из создателей современного математического анализа, теории дифференциальных уравнений и др.

На рис. 10.5 изображена геометрическая иллюстрация этого метода для минимизации функции двух переменных. Из начальной точки  $\mathbf{x}^{(0)}$  перпендикулярно линии уровня  $f(\mathbf{x}) = f(\mathbf{x}^{(0)})$  в направлении  $\mathbf{p}^{(0)} = -\mathbf{g}^{(0)}$  спуск продолжают до тех пор, пока не будет достигнуто минимальное вдоль луча  $\mathbf{x}^{(0)} + \alpha \mathbf{p}^{(0)}$  ( $\alpha > 0$ ) значение функции  $f$ . В найденной точке  $\mathbf{x}^{(1)}$  этот луч касается линии уровня  $f(\mathbf{x}) = f(\mathbf{x}^{(1)})$ . Затем из точки  $\mathbf{x}^{(1)}$  проводят спуск в перпендикулярном линии уровня направлении  $\mathbf{p}^{(1)} = -\mathbf{g}^{(1)}$  до тех пор, пока соответствующий луч не коснется в точке  $\mathbf{x}^{(2)}$  проходящей через эту точку линии уровня, и т. д.

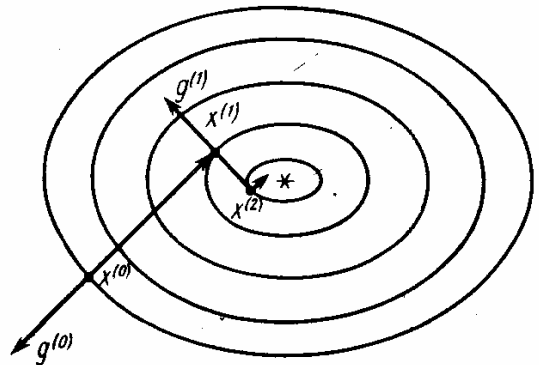


Рис. 10.5

Отметим, что на каждой итерации выбор шага  $\alpha_n$  предполагает решение задачи одномерной минимизации (10.23). Иногда эту операцию удается выполнить аналитически, например для квадратичной функции.

Применим метод наискорейшего спуска для минимизации квадратичной функции

$$F(\mathbf{x}) = \frac{1}{2} (\mathbf{Ax}, \mathbf{x}) - (\mathbf{b}, \mathbf{x}) \quad (10.24)$$

с симметричной положительно определенной матрицей  $\mathbf{A}$ .

Согласно формуле (10.8), в этом случае  $\mathbf{g}^{(n)} = \mathbf{Ax}^{(n)} - \mathbf{b}$ . Поэтому формула (10.22) выглядит здесь так:

$$\mathbf{x}^{(n+1)} = \mathbf{x}^{(n)} - \alpha_n (\mathbf{Ax}^{(n)} - \mathbf{b}). \quad (10.25)$$

Заметим, что

$$\begin{aligned} \varphi_n(\alpha) &= \frac{1}{2} (\mathbf{A}(\mathbf{x}^{(n)} - \alpha \mathbf{g}^{(n)}), \mathbf{x}^{(n)} - \alpha \mathbf{g}^{(n)}) - (\mathbf{b}, \mathbf{x}^{(n)} - \alpha \mathbf{g}^{(n)}) = \\ &= \frac{1}{2} (\mathbf{Ag}^{(n)}, \mathbf{g}^{(n)}) \alpha^2 - (\mathbf{g}^{(n)}, \mathbf{g}^{(n)}) \alpha + \frac{1}{2} (\mathbf{Ax}^{(n)}, \mathbf{x}^{(n)}) - (\mathbf{b}, \mathbf{x}^{(n)}). \end{aligned}$$

Эта функция является квадратичной функцией параметра  $\alpha$  и достигает минимума при таком значении  $\alpha = \alpha_n$ , для которого

$$\varphi_n'(\alpha_n) = (\mathbf{Ag}^{(n)}, \mathbf{g}^{(n)}) \alpha_n - (\mathbf{g}^{(n)}, \mathbf{g}^{(n)}) = 0.$$

Таким образом, применительно к минимизации квадратичной функ-

ции (10.24) метод наискорейшего спуска эквивалентен расчету по формуле (10.25), где

$$\alpha_n = \frac{(g^{(n)}, g^{(n)})}{(Ag^{(n)}, g^{(n)})}. \quad (10.26)$$

**З а м е ч а н и е 1.** Поскольку точка минимума функции (10.24) совпадает с решением системы  $Ax = b$ , метод наискорейшего спуска (10.25), (10.26) может применяться и как итерационный метод решения систем линейных алгебраических уравнений с симметричными положительно определенными матрицами.

**З а м е ч а н и е 2.** Отметим, что  $\alpha_n^{-1} = \rho(g^{(n)})$ , где  $\rho(x) = (Ax, x)/(x, x)$  — отношение Рэля (см. § 8.1).

**Пример 10.1.** Применим метод наискорейшего спуска для минимизации квадратичной функции  $f(x_1, x_2) = x_1^2 + 2x_2^2 - 4x_1 - 4x_2$ .

Заметим, что  $f(x_1, x_2) = (x_1 - 2)^2 + 2(x_2 - 1)^2 - 6$ . Поэтому точное значение  $\bar{x} = (2, 1)^T$  точки минимума нам заранее известно. Запишем данную функцию в виде (10.24), где матрица  $A = \begin{bmatrix} 2 & 0 \\ 0 & 4 \end{bmatrix}$  и вектор  $b = (4, 4)^T$ . Как нетрудно видеть,  $A = A^T > 0$ .

Возьмем начальное приближение  $x^{(0)} = (0, 0)^T$  и будем вести вычисления по формулам (10.25), (10.26).

$$\begin{aligned} \text{I и т е р а ц и я. } g^{(0)} &= Ax^{(0)} - b = (-4, -4)^T, \quad \alpha_0 = \frac{(g^{(0)}, g^{(0)})}{(Ag^{(0)}, g^{(0)})} = \\ &= \frac{4^2 + 4^2}{2 \cdot 4^2 + 4 \cdot 4^2} = \frac{1}{3}, \quad x^{(1)} = x^{(0)} - \alpha_0 g^{(0)} = (4/3, 4/3)^T. \end{aligned}$$

$$\begin{aligned} \text{II и т е р а ц и я. } g^{(1)} &= Ax^{(1)} - b = (-4/3, 4/3)^T, \quad \alpha_1 = \frac{(g^{(1)}, g^{(1)})}{(Ag^{(1)}, g^{(1)})} = \\ &= \frac{(4/3)^2 + (4/3)^2}{2 \cdot (4/3)^2 + 4 \cdot (4/3)^2} = \frac{1}{3}, \quad x^{(2)} = x^{(1)} - \alpha_1 g^{(1)} = (16/9, 8/9)^T. \end{aligned}$$

Можно показать, что для всех  $n \geq 1$  на  $n$ -й итерации будут получены значения

$$g^{(n)} = \frac{-4}{3^n} (1, (-1)^n)^T, \quad \alpha_n = \frac{1}{3}, \quad x^{(n)} = \bar{x} - \frac{1}{3^n} (2, (-1)^n)^T.$$

Заметим, что  $|x^{(n)} - \bar{x}| = \frac{\sqrt{5}}{3^n} \rightarrow 0$  при  $n \rightarrow \infty$ . Таким образом, последова-

тельность  $\mathbf{x}^{(n)}$ , полученная методом наискорейшего спуска, сходится со скоростью геометрической прогрессии, знаменатель которой  $q = 1/3$ .

На рис. 10.5 изображена именно та траектория спуска, которая была получена в данном примере.

Для случая минимизации квадратичной функции справедлив следующий общий результат [18].

**Теорема 10.1.** Пусть  $A$  — симметричная положительно определенная матрица и минимизируется квадратичная функция (10.24). Тогда при любом выборе начального приближения метод наискорейшего спуска (10.25), (10.26) сходится и верна следующая оценка погрешности:

$$|\mathbf{x}^{(n)} - \bar{\mathbf{x}}| \leq \sqrt{\frac{\lambda_{\max}}{\lambda_{\min}}} \left[ \frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}} \right]^n |\mathbf{x}^{(0)} - \bar{\mathbf{x}}|. \quad (10.27)$$

Здесь  $\lambda_{\min}$  и  $\lambda_{\max}$  — минимальное и максимальное собственные значения матрицы  $A$ .

Отметим, что этот метод сходится со скоростью геометрической прогрессии, знаменатель которой  $q = (\lambda_{\max} - \lambda_{\min})/(\lambda_{\max} + \lambda_{\min})$ , причем если  $\lambda_{\min}$  и  $\lambda_{\max}$  близки, то  $q$  мало и метод сходится достаточно быстро. Например, в примере 10.1 имеем  $\lambda_{\min} = 2$ ,  $\lambda_{\max} = 4$  и поэтому  $q = (4 - 2)/(4 + 2) = 1/3$ . Если же  $\lambda_{\min} \ll \lambda_{\max}$ , то  $q \approx 1$  и следует ожидать медленной сходимости метода наискорейшего спуска.

**Пример 10.2.** Применение метода наискорейшего спуска для минимизации квадратичной функции  $f(x_1, x_2) = x_1^2 + 10x_2^2 - 4x_1 - 4x_2$  при начальном приближении  $\mathbf{x}^{(0)} = (0, 0)^T$  дает последовательность приближений  $\mathbf{x}^{(n)} = \bar{\mathbf{x}} - 2\left[\frac{9}{11}\right]^n \cdot (1, (-1)^n)^T$ , где  $\bar{\mathbf{x}} = (2, 0.2)^T$ . Траектория спуска изображена на рис. 10.6.




Рис. 10.6

Последовательность  $\mathbf{x}^{(n)}$  сходится здесь со скоростью геометрической прогрессии, знаменатель которой равен  $q = 9/11$ , т. е. существенно медленнее,



чем в предыдущем примере. Так как здесь  $A = \begin{bmatrix} 2 & 0 \\ 0 & 20 \end{bmatrix}$ , то  $\lambda_{\min} = 2$ ,  $\lambda_{\max} = 20$ ,  $(\lambda_{\max} - \lambda_{\min})/(\lambda_{\max} + \lambda_{\min}) = 9/11$ , и полученный результат вполне согласуется с оценкой (10.27).

**З а м е ч а н и е 1.** Мы сформулировали теорему о сходимости метода наискорейшего спуска в случае, когда целевая функция является квадратичной. В общем случае, если минимизируемая функция строго выпуклая и имеет точку минимума  $\bar{x}$ , то также независимо от выбора начального приближения полученная указанным методом последовательность  $x^{(n)}$  сходится к  $\bar{x}$  при  $n \rightarrow \infty$ . При этом после попадания  $x^{(n)}$  в достаточно малую окрестность точки минимума сходимость становится линейной и знаменатель соответствующей геометрической прогрессии оценивается сверху величиной  $q \approx (\lambda_{\max} - \lambda_{\min})/(\lambda_{\max} + \lambda_{\min})$ , где  $\lambda_{\min}$  и  $\lambda_{\max}$  — минимальное и максимальное собственные числа матрицы Гессе  $G(\bar{x})$ .

**З а м е ч а н и е 2.** Для квадратичной целевой функции (10.24) решение задачи одномерной минимизации (10.23) удастся найти в виде простой явной формулы (10.26). Однако для большинства других нелинейных функций этого сделать нельзя и для вычисления  $\alpha_n$  методом наискорейшего спуска приходится применять численные методы одномерной минимизации типа тех, которые были рассмотрены в предыдущей главе.

**2. Проблема "оврагов".** Из проведенного выше обсуждения следует, что градиентный метод сходится достаточно быстро, если для минимизируемой функции поверхности уровня близки к сферам (при  $m = 2$  линии уровня близки к окружностям). Для таких функций  $\kappa = \lambda_{\max}/\lambda_{\min} \approx 1$ . Теорема 10.1, замечание 1, а также результат примера 10.2 указывают на то, что скорость сходимости резко падает при увеличении величины  $\kappa$ . Действительно, известно, что градиентный метод сходится очень медленно, если поверхности уровня минимизируемой функции сильно вытянуты в некоторых направлениях. В двумерном случае рельеф соответствующей поверхности  $u = f(x_1, x_2)$  напоминает рельеф местности с оврагом (рис. 10.7). Поэтому такие функции принято называть *овражными*. Вдоль направлений, характеризующих "дно оврага", овражная функция меняется незначительно, а в других направлениях, характеризующих "склон оврага", происходит резкое изменение функции.

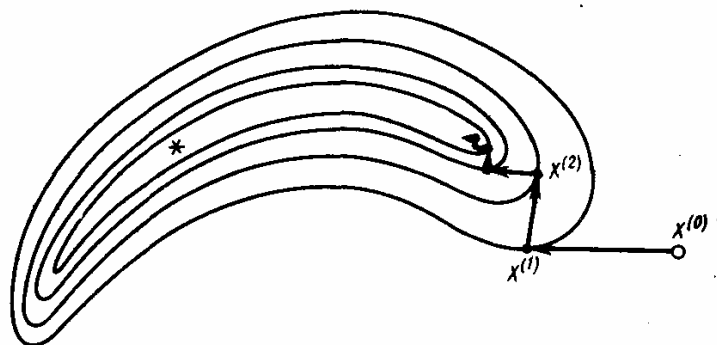


Рис. 10.7

Если начальная точка  $\mathbf{x}^{(0)}$  попадает на "склон оврага", то направление градиентного спуска оказывается почти перпендикулярным "дну оврага" и очередное приближение  $\mathbf{x}^{(1)}$  попадает на противоположный "склон оврага". Следующий шаг в направлении ко "дну оврага" возвращает приближение  $\mathbf{x}^{(2)}$  на первоначальный "склон оврага". В результате вместо того чтобы двигаться вдоль "дна оврага" в направлении к точке минимума, траектория спуска совершает зигзагообразные скачки поперек "оврага", почти не приближаясь к цели (рис. 10.7).

Для ускорения сходимости градиентного метода при минимизации овражных функций разработан ряд специальных "овражных" методов. Дадим представление об одном из простейших приемов. Из двух близких начальных точек  $\mathbf{z}^{(0)}$  и  $\mathbf{z}^{(1)}$  совершают градиентный спуск на "дно оврага". Через найденные точки  $\mathbf{x}^{(0)}$  и  $\mathbf{x}^{(1)}$  проводят прямую, вдоль которой совершают большой "овражный" шаг (рис. 10.8). Из найденной таким образом точки  $\mathbf{z}^{(2)}$  снова делают один шаг градиентного спуска в точку  $\mathbf{x}^{(2)}$ . Затем совершают второй "овражный" шаг вдоль прямой, проходящей через точки  $\mathbf{x}^{(1)}$  и  $\mathbf{x}^{(2)}$ , и т. д. В результате движение вдоль "дна оврага" к точке минимума существенно ускоряется.




Рис. 10.8

Более подробную информацию о проблеме "оврагов" и "овражных" методах можно найти, например, в [9], [18].

3. Другие подходы к определению шага спуска. Как нетрудно понять, на каждой итерации было бы желательно выбирать направление спуска  $\mathbf{p}^{(n)}$ , близкое к тому направлению, перемещение вдоль которого приводит из точки  $\mathbf{x}^{(n)}$  в точку  $\bar{\mathbf{x}}$ . К сожалению, антиградиент  $\mathbf{p}^{(n)} = -\mathbf{g}^{(n)}$  является, как правило, неудачным направлением спуска. Особенно ярко это проявляется для овражных функций. Поэтому возникает сомнение в целесообразности тщательного поиска решения задачи одномерной минимизации (10.23) и появляется желание сделать в направлении  $\mathbf{p}^{(n)}$  лишь такой шаг, который бы обеспечил "существенное убывание" функции  $f$ . Более того, на практике иногда довольствуются определением значения  $\alpha_n > 0$ , которое просто обеспечивает уменьшение значения целевой функции.

В одном из простейших алгоритмов (типа дробления шага) такого выбора шага  $\alpha_n$  фиксируют начальное значение  $\alpha > 0$  и значение параметра  $\gamma$ ,  $0 < \gamma < 1$ . За  $\alpha_n$  принимают  $\alpha_n = \alpha \cdot \gamma^{i_n}$ , где  $i_n$  — первый из номеров  $i = 0, 1, 2, \dots$ , для которого выполнено условие убывания

$$f(\mathbf{x}^{(n)} - \alpha \gamma^i \mathbf{g}^{(n)}) - f(\mathbf{x}^{(n)}) < 0. \quad (10.28)$$

Однако при таком выборе  $\alpha_n$  нет гарантии, что последовательность  $\mathbf{x}^{(n)}$  будет сходиться к точке минимума даже для простой квадратичной функции (10.24). Условие (10.28) является слишком слабым: последовательность  $\mathbf{x}^{(n)}$ , незначительно уменьшая значения функции  $f$ , может "останавливаться", не доходя до точки  $\bar{\mathbf{x}}$ . Такое поведение последовательности  $\mathbf{x}^{(n)}$  можно предотвратить, если заменить условие (10.28) условием "существенного убывания" функции  $f$  на каждой итерации:

$$f(\mathbf{x}^{(n)} - \alpha \gamma^i \mathbf{g}^{(n)}) - f(\mathbf{x}^{(n)}) \leq -\beta \alpha \gamma^i \|\mathbf{g}^{(n)}\|^2. \quad (10.29)$$

Здесь  $\beta$  ( $0 < \beta < 1$ ) — дополнительный параметр. Заметим, что для рассматриваемого метода  $\mathbf{p}^{(n)} = -\mathbf{g}^{(n)} = -f'(\mathbf{x}^{(n)})$  и поэтому неравенство (10.29) в точности совпадает с неравенством (10.15), используемым в методах спуска при дроблении шага.

**Пример 10.3.** Продемонстрируем применение градиентного метода с дроблением шага к задаче минимизации квадратичной функции  $f(x_1, x_2) = x_1^2 + 2x_2^2 - 4x_1 - 4x_2$  из примера 10.1. Для выбора значения шага будем использовать условие (10.29). Воспользуемся следующими краткими обозначениями:  $\alpha_i = \alpha \gamma^i$ ,  $\mathbf{x}^{(n,i)} = \mathbf{x}^{(n)} - \alpha_i \mathbf{g}^{(n)}$ . Заметим, что  $\mathbf{g}^{(n)} = (2x_1^{(n)} - 4, 4x_2^{(n)} - 4)^T$ .

Выберем начальное приближение  $\mathbf{x}^{(0)} = (0, 0)^T$ , начальное значение шага  $\alpha = \alpha_0 = 1$ , значения параметров  $\gamma = 1/2$ ,  $\beta = 3/4$ . Вычислим значения  $f(\mathbf{x}^{(0)}) = 0$ ,  $\mathbf{g}^{(0)} = (-4, -4)^T$ .

**И т е р а ц и я.** Вычисляем  $\mathbf{x}^{(0,0)} = \mathbf{x}^{(0)} - \alpha_0 \mathbf{g}^{(0)} = (4, 4)^T$ ,  $f(\mathbf{x}^{(0,0)}) = 16$ . Так как значение функции не уменьшилось, то следует уменьшить шаг:  $\alpha_1 = \alpha_0/2 = 0.5$ .

Вычисляем  $\mathbf{x}^{(0,1)} = \mathbf{x}^{(0)} - \alpha_1 \mathbf{g}^{(0)} = (2, 2)^T$ ,  $f(\mathbf{x}^{(0,1)}) = -4$ . Поскольку  $f(\mathbf{x}^{(0,1)}) - f(\mathbf{x}^{(0)}) = -4 > -\beta \alpha_1 |\mathbf{g}^{(0)}|^2 = -12$ , условие (10.29) не выполняется и следует снова уменьшить шаг:  $\alpha_2 = \alpha_1/2 = 0.25$ .

Вычисляем  $\mathbf{x}^{(0,2)} = \mathbf{x}^{(0)} - \alpha_2 \mathbf{g}^{(0)} = (1, 1)^T$ ,  $f(\mathbf{x}^{(0,2)}) = -5$ . Имеем  $f(\mathbf{x}^{(0,2)}) - f(\mathbf{x}^{(0)}) = -5 > -\beta \alpha_2 |\mathbf{g}^{(0)}|^2 = -6$ , т. е. условие (10.29) не выполняется. Уменьшаем шаг:  $\alpha_3 = \alpha_2/2 = 0.125$ .

Вычисляем  $\mathbf{x}^{(0,3)} = \mathbf{x}^{(0)} - \alpha_3 \mathbf{g}^{(0)} = (0.5, 0.5)^T$ ,  $f(\mathbf{x}^{(0,3)}) = -3.25$ . Так как  $f(\mathbf{x}^{(0,3)}) - f(\mathbf{x}^{(0)}) = -3.25 < -\beta \alpha_3 |\mathbf{g}^{(0)}|^2 = -3$ , то условие (10.29) выполнено.

Положим  $\mathbf{x}^{(1)} = (0.5, 0.5)^T$ ; напомним, что  $f(\mathbf{x}^{(1)}) = -3.25$ . Вычислим  $\mathbf{g}^{(1)} = (-3, -2)^T$  и положим  $\alpha_0 = 1$ .

Далее вычисления следует продолжить до выполнения какого-либо принятого критерия окончания итераций.

**4. Влияние погрешности вычислений.** Один из существенных недостатков градиентного метода связан с его чувствительностью к погрешностям вычислений. Особенно сильно этот недостаток сказывается в малой окрестности точки минимума, где антиградиент, задающий направление поиска, мал по модулю. Поэтому эффективность градиентного метода на завершающей стадии поиска существенно ниже, чем на начальной стадии.

## § 10.4. Метод Ньютона

**1. Простейший вариант метода Ньютона и метод Ньютона с дроблением шага.** Пусть в некоторой окрестности точки минимума  $\bar{\mathbf{x}}$  функция  $f$  является сильно выпуклой и дважды непрерывно дифференцируемой. Далее, пусть  $\mathbf{x}^{(n)}$  — хорошее приближение к  $\bar{\mathbf{x}}$ . Тогда в малой окрестности точки  $\mathbf{x}^{(n)}$  функция  $f$  достаточно точно аппроксимируется квадратичной функцией  $F_n(\mathbf{x}) = f(\mathbf{x}^{(n)}) + (\mathbf{g}^{(n)}, \mathbf{x} - \mathbf{x}^{(n)}) + \frac{1}{2} (G^{(n)}(\mathbf{x} - \mathbf{x}^{(n)}), \mathbf{x} - \mathbf{x}^{(n)})$ , являющейся суммой первых трех членов ее разложения по формуле Тейлора (ср. с формулой (10.9)). Здесь  $\mathbf{g}^{(n)} = f'(\mathbf{x}^{(n)})$ ,  $G^{(n)} = f''(\mathbf{x}^{(n)})$ .

Можно ожидать, что точка  $\bar{x}^{(n)}$ , в которой достигается минимум функции  $F_n$ , будет значительно лучшим приближением к  $\bar{x}$ , чем  $x^{(n)}$ . Учитывая, что  $F'_n(x) = g^{(n)} + G^{(n)}(x - x^{(n)})$ , замечаем, что точка  $\bar{x}^{(n)}$  может быть определена из необходимого условия экстремума:

$$g^{(n)} + G^{(n)}(\bar{x}^{(n)} - x^{(n)}) = 0.$$

Таким образом, чтобы попасть из точки  $x^{(n)}$  в точку  $\bar{x}^{(n)}$ , нужно переместиться вдоль вектора  $p^{(n)} = \bar{x}^{(n)} - x^{(n)}$ , который определяется из системы линейных алгебраических уравнений

$$G^{(n)} p^{(n)} = -g^{(n)}. \quad (10.30)$$

Вектор  $p^{(n)}$  принято называть *ньютонovskyм направлением*, а метод спуска

$$x^{(n+1)} = x^{(n)} + \alpha_n p^{(n)} \quad (10.31)$$

с таким выбором  $p^{(n)}$  — *методом Ньютона*.

Отметим, что ньютонovskyе направление является направлением спуска. В самом деле, в силу равенства (10.30) для  $p^{(n)}$  верна формула  $p^{(n)} = -[G^{(n)}]^{-1}g^{(n)}$ . Матрица  $[G^{(n)}]^{-1}$  положительно определена (это следует из положительной определенности матрицы  $G^{(n)}$ ). Поэтому

$$(f'(x^{(n)}), p^{(n)}) = -([G^{(n)}]^{-1}g^{(n)}, g^{(n)}) < 0.$$

Таким образом, условие (10.14) выполняется и  $p^{(n)}$  действительно задает направление спуска.

Различные варианты метода (10.31), (10.30) связаны с различными способами выбора шагов  $\alpha_n$ . Заметим, что при выборе  $\alpha_n = 1$  рассматриваемый метод в точности совпадает с методом Ньютона решения систем нелинейных уравнений, примененным к решению системы  $f'(x) = 0$ . Отсюда — и название метода.

Простым следствием теоремы 7.3 о сходимости метода Ньютона решения систем нелинейных уравнений является следующая теорема.

**Т е о р е м а 10.2.** Пусть в некоторой окрестности  $U$  точки минимума  $\bar{x}$  функция  $f$  является сильно выпуклой и трижды непрерывно дифференцируемой. Тогда найдется такая малая  $\delta$ -окрестность точки  $\bar{x}$ , что при произвольном выборе начального приближения  $x^{(0)}$  из этой окрестности последовательность  $x^{(n)}$ , вычисляемая с помощью мето-

да (10.30), (10.31) при  $\alpha_n = 1$ , не выходит за пределы  $\delta$ -окрестности точки  $\bar{x}$  и сходится к ней квадратично.

**З а м е ч а н и е.** Квадратичная скорость сходимости метода позволяет использовать простой практический критерий окончания:

$$|x^{(n+1)} - x^{(n)}| < \varepsilon. \quad (10.32)$$

Теорема 10.2 указывает на то, что метод Ньютона сходится очень быстро, и практика вычислений это подтверждает. Однако существенным недостатком рассмотренного варианта метода является необходимость выбора достаточно хорошего начального приближения, которое на начальной стадии поиска точки минимума, как правило, отсутствует. Поэтому метод Ньютона с выбором  $\alpha_n = 1$  чаще применяют на завершающем этапе поиска  $\bar{x}$ , когда с помощью других методов уже найдено достаточно точное приближение к точке минимума.

Указанного недостатка в значительной степени лишен вариант метода Ньютона, в котором в качестве шага спуска выбирается  $\alpha_n = \gamma^{i_n}$ , где  $i_n$  — первый среди номеров  $i \geq 0$ , для которых выполняется неравенство  $f(x^{(n)} + \gamma^i p^{(n)}) - f(x^{(n)}) \leq \beta \gamma^i (g^{(n)}, p^{(n)})$ . Здесь  $0 < \gamma < 1$ ,  $0 < \beta < 1/2$  — параметры метода. Метод Ньютона с таким выбором  $\alpha_n$  для широкого класса функций сходится при любом выборе начального приближения  $x^{(0)} \in U$  и этим выгодно отличается от метода с выбором  $\alpha_n = 1$ .

**Т е о р е м а 10.3.** Пусть трижды непрерывно дифференцируемая в  $R^m$  функция  $f$  имеет точку минимума  $\bar{x}$  и ее матрица Гессе  $f''(x)$  положительно определена. Тогда при любом начальном приближении  $x^{(0)}$  последовательность  $x^{(n)}$ , вычисляемая методом Ньютона с выбором  $\alpha_n = \gamma^{i_n}$  сходится к  $\bar{x}$  с квадратичной скоростью. Более того, найдется номер  $n_0$  такой, что для всех  $n \geq n_0$  выполняется равенство  $\alpha_n = 1$ .

**З а м е ч а н и е.** Используют и другие способы выбора  $\alpha_n$ . Например, иногда  $\alpha_n$  выбирают из условия  $\varphi_n(\alpha_n) = \min_{0 \leq \alpha \leq 1} \varphi_n(\alpha)$ , где

$$\varphi_n(\alpha) = f(x^{(n)} + \alpha p^{(n)}).$$

Квадратичная скорость сходимости метода Ньютона, а также возможность использования матрицы Гессе для контроля за соблюдением достаточных условий экстремума делают этот метод чрезвычайно привлекательным при решении задачи безусловной минимизации.

**Пример 10.4.** Применим метод Ньютона (10.30), (10.31) с  $\alpha_n = 1$  для поиска точки минимума функции  $f(x_1, x_2) = x_1^2 + 10(x_2 - \sin x_1)^2$  с точностью  $\epsilon = 10^{-5}$ . Будем использовать критерий окончания итераций (10.32) и вести вычисления на 6-разрядной десятичной ЭВМ. Отметим, что минимальное и равное нулю значение функция  $f$  достигает в точке  $\bar{x} = (0, 0)^T$ .

Имеем

$$\begin{aligned} g^{(n)} &= f'(x_1^{(n)}, x_2^{(n)}) = \\ &= (2x_1^{(n)} + 20(\sin x_1^{(n)} - x_2^{(n)}) \cdot \cos x_1^{(n)}, 20(x_2^{(n)} - \sin x_1^{(n)}))^T, \\ G^{(n)} &= f''(x^{(n)}) = \begin{bmatrix} 2 + 20(\cos 2x_1^{(n)} + x_2^{(n)} \cdot \sin x_1^{(n)}) & -20\cos x_1^{(n)} \\ -20\cos x_1^{(n)} & 20 \end{bmatrix}. \end{aligned}$$

Возьмем за начальное приближение  $x^{(1)} = (1, 1)^T$ .

**И т е р а ц и я.** Вычислим

$$g^{(0)} = \begin{bmatrix} 0.286928 \\ 3.17058 \end{bmatrix}, \quad G^{(0)} = \begin{bmatrix} 10.5065 & -10.8060 \\ -10.8060 & 20 \end{bmatrix}.$$

Таким образом, при  $n = 0$  система (10.30) принимает следующий вид:

$$\begin{aligned} 10.5065p_1^{(0)} - 10.8060p_2^{(0)} &= -0.286928, \\ -10.8060p_1^{(0)} + 20p_2^{(0)} &= -3.17058. \end{aligned}$$

Решая ее, получаем  $p_1^{(0)} = -0.428445$ ,  $p_2^{(0)} = -0.390018$ . Далее в соответствии с формулой (10.31) полагаем  $x_1^{(1)} = x_1^{(0)} + p_1^{(0)} = 0.571555$ ,  $x_2^{(1)} = x_2^{(0)} + p_2^{(0)} = 0.609982$ . Так как  $|x^{(1)} - x^{(0)}| \approx 0.6 > \epsilon$ , то вычисления следует продолжить далее.

Результаты следующих итераций приведены в табл. 10.1.

Т а б л и ц а 10.1

$n$	$x_1^{(n)}$	$x_2^{(n)}$	$ x^{(n)} - x^{(n-1)} $
0	1.00000000	1.00000000	
1	0.57155400	0.60997200	$6 \cdot 10^{-1}$
2	0.15541900	0.19094400	$6 \cdot 10^{-1}$
3	0.00824200	0.00939200	$2 \cdot 10^{-1}$
4	0.00000082	0.00000101	$1 \cdot 10^{-2}$
5	0.00000000	0.00000922	$2 \cdot 10^{-6}$

При  $n = 5$  критерий окончания выполняется и вычисления следует прекратить. Итак,  $\bar{x} \approx (0.00000, 0.00000)^T$ .

**2. Понятие о квазиньютоновских методах.** Высокая скорость сходимости метода Ньютона связана с тем, что в нем используется матрица Гессе, содержащая информацию о кривизнах функции  $f$ . В результате минимизируемую функцию удастся достаточно точно аппроксимировать последовательностью квадратичных функций  $F_n$ . В методах, которые называют *квазиньютоновскими*<sup>1</sup>, также фактически используется квадратичная аппроксимация функции  $f$ , но в отличие от метода Ньютона в них не применяется вычисление вторых производных. Информация о кривизнах функции  $f$  здесь накапливается постепенно и является результатом наблюдений за изменением градиента  $g^{(n)}$ .

Направление спуска в квазиньютоновских методах определяется как решение системы уравнений

$$B^{(n)} p^{(n)} = -g^{(n)},$$

в которой  $B^{(n)}$  — текущее приближение к матрице Гессе. Начальное приближение  $B^{(0)}$  обычно полагают равным единичной матрице. В таком случае  $p^{(0)} = -g^{(0)}$  и первая итерация совпадает с одним шагом градиентного метода.

После того, как найдено приближение  $x^{(n+1)}$ , вычисляют матрицу  $B^{(n+1)} = B^{(n)} + \Delta B^{(n)}$ , где  $\Delta B^{(n)}$  — некоторая поправочная матрица. Во всех правилах пересчета неизменным является выполнение *квазиньютоновского условия*

$$B^{(n+1)}(x^{(n+1)} - x^{(n)}) = g^{(n+1)} - g^{(n)}.$$

Известно, что при определенных условиях квазиньютоновские методы сходятся сверхлинейно. Для квадратичных же функций они дают точное значение точки минимума после конечного числа итераций, которое не превышает<sup>2</sup>  $m$ .

Первый из квазиньютоновских методов был предложен в 1959 г. Дэвидоном. С тех пор эти методы непрерывно совершенствовались и к настоящему времени стали одними из наиболее популярных и широко

<sup>1</sup> Первоначально эти методы называли методами переменной метрики.

<sup>2</sup> Естественно, что это верно только при отсутствии вычислительной погрешности.



применяемых на практике. Весьма интересное и содержательное обсуждение квазиньютоновских методов содержится в книгах [24], [32], [91].

**З а м е ч а н и е.** В некоторых вариантах квазиньютоновских методов направление спуска вычисляется по формуле  $p^{(n)} = -H^{(n)} g^{(n)}$ , где  $H^{(n)}$  — матрица, аппроксимирующая матрицу, обратную матрице Гессе.

**3. Метод Ньютона и квазиньютоновские методы при наличии помех.** Вычислительные ошибки (помехи) оказывают существенное влияние на поведение метода Ньютона. Природа этих ошибок может быть различной (вычисление  $g^{(n)}$ , решение системы уравнений  $G^{(n)} p^{(n)} = -g^{(n)}$  и др.). В результате вместо ньютоновского направления  $p^{(n)}$  получается направление  $p_*^{(n)}$ . Пусть  $|p^{(n)} - p_*^{(n)}| < \epsilon$ . Как известно, метод Ньютона сходится, вообще говоря, лишь в некоторой окрестности  $U$  точки минимума. В случае, когда радиус этой окрестности меньше  $\epsilon$ , очередное приближение  $x^{(n+1)} = x^{(n)} + \alpha_n p_*^{(n)}$  скорее всего окажется вне окрестности  $U$  и метод не будет сходиться. Таким образом, метод Ньютона сохраняет свои преимущества лишь при высокой точности вычислений.

Квазиньютоновские методы оказываются весьма чувствительны к ошибкам в вычислении градиента. Причина здесь состоит в том, что в основе этих методов лежит идея восстановления матрицы Гессе по результатам вычисления градиента  $f'(x)$  в точках  $x^{(n)}$ . Как и в методе Ньютона, здесь необходимо очень аккуратное вычисление градиента.

## § 10.5. Метод сопряженных градиентов

Метод Ньютона и квазиньютоновские методы, обсуждавшиеся в предыдущем параграфе, весьма эффективны как средство решения задач безусловной минимизации. Однако они предъявляют довольно высокие требования к объему используемой памяти ЭВМ. Это связано с тем, что выбор направления поиска  $p^{(n)}$  требует решения систем линейных уравнений, а также с возникающей необходимостью хранения матриц типа  $B^{(n)}$ ,  $H^{(n)}$ . Поэтому при больших  $n$  использование этих методов может оказаться невозможным. В существенной степени от этого недостатка избавлены методы сопряженных направлений.

**1. Понятие о методах сопряженных направлений.** Рассмотрим задачу минимизации квадратичной функции

$$F(x) = \frac{1}{2} (Ax, x) - (b, x) \quad (10.33)$$

с симметричной положительно определенной матрицей  $A$ . Напомним, что для ее решения требуется один шаг метода Ньютона и не более чем  $m$  шагов квазиньютоновского метода. Методы сопряженных направлений также позволяют найти точку минимума функции (10.33) не более чем за  $m$  шагов. Добиться этого удастся благодаря специальному выбору направлений поиска.

Будем говорить, что ненулевые векторы  $p^{(0)}, p^{(1)}, \dots, p^{(m-1)}$  являются *взаимно сопряженными* (относительно матрицы  $A$ ), если  $(Ap^{(n)}, p^{(l)}) = 0$  для всех  $n \neq l$ .

Под *методом сопряженных направлений* для минимизации квадратичной функции (10.33) будем понимать метод

$$x^{(n+1)} = x^{(n)} + \alpha_n p^{(n)} \quad (n = 0, 1, 2, \dots, m-1),$$

в котором направления  $p^{(0)}, p^{(1)}, \dots, p^{(m-1)}$  взаимно сопряжены, а шаги

$$\alpha_n = - \frac{(g^{(n)}, p^{(n)})}{(Ap^{(n)}, p^{(n)})}$$

получаются как решение задач одномерной минимизации:

$$\varphi_n(\alpha_n) = \min_{\alpha \geq 0} \varphi_n(\alpha), \quad \varphi_n(\alpha) = F(x^{(n)} + \alpha p^{(n)}).$$

**Теорема 10.4.** *Метод сопряженных направлений позволяет найти точку минимума квадратичной функции (10.33) не более чем за  $m$  шагов.*

Методы сопряженных направлений отличаются один от другого способом построения сопряженных направлений. Наиболее известным среди них является *метод сопряженных градиентов*.

**2. Метод сопряженных градиентов.** В этом методе направления  $p^{(n)}$  строят по правилу

$$p^{(0)} = -g^{(0)}, \quad p^{(n)} = -g^{(n)} + \beta_{n-1} p^{(n-1)}, \quad n \geq 1, \quad (10.34)$$

где

$$\beta_{n-1} = \frac{(Ap^{(n-1)}, g^{(n)})}{(Ap^{(n-1)}, p^{(n-1)})}. \quad (10.35)$$

Так как  $p^{(0)} = -g^{(0)}$ , то первый шаг этого метода совпадает с шагом метода наискорейшего спуска. Можно показать (мы этого делать не будем), что направления (10.34) действительно являются сопряжен-

ными относительно матрицы  $A$ . Более того, градиенты  $g^{(n)}$  ( $n = 0, 1, \dots, m-1$ ) оказываются взаимно ортогональными.

**Пример 10.5.** Применим метод сопряженных градиентов для минимизации квадратичной функции  $f(x_1, x_2) = x_1^2 + 2x_2^2 - 4x_1 - 4x_2$  из примера 10.1.

Запишем  $f$  в виде  $\frac{1}{2}(Ax, x) - (b, x)$ , где

$$A = \begin{bmatrix} 2 & 0 \\ 0 & 4 \end{bmatrix}, \quad b = \begin{bmatrix} 4 \\ 4 \end{bmatrix}.$$

Возьмем начальное приближение  $x^{(0)} = (0, 0)^T$ .

1-й шаг метода совпадает с первым шагом метода наискорейшего спуска. Поэтому (см. пример 10.1)  $g^{(0)} = (-4, -4)^T$ ,  $p^{(0)} = -g^{(0)}$ ,  $x^{(1)} = (4/3, 4/3)^T$ .

2-й шаг. Вычислим  $g^{(1)} = Ax^{(1)} - b = (-4/3, 4/3)^T$ ,

$$\beta_0 = \frac{(Ap^{(0)}, g^{(1)})}{(Ap^{(0)}, p^{(0)})} = \frac{8 \cdot (-4/3) + 16 \cdot (4/3)}{8 \cdot 4 + 16 \cdot 4} = \frac{1}{9},$$

$$p^{(1)} = -g^{(1)} + \beta_0 p^{(0)} = (4/3, -4/3)^T + (1/9)(4, 4)^T = (16/9, -8/9)^T,$$

$$\alpha_1 = -\frac{(g^{(1)}, p^{(1)})}{(Ap^{(1)}, p^{(1)})} = -\frac{(-4/3) \cdot (16/9) + (4/3) \cdot (-8/9)}{(32/9) \cdot (16/9) + (-32/9) \cdot (-8/9)} = \frac{3}{8},$$

$$x^{(2)} = x^{(1)} + \alpha_1 p^{(1)} = (4/3, 4/3)^T + (3/8)(16/9, -8/9)^T = (2, 1)^T.$$

Так как  $g^{(2)} = Ax^{(2)} - b = 0$ , то  $\bar{x} = x^{(2)} = (2, 1)^T$  и решение оказалось найденным за два шага.

**3. Метод сопряженных градиентов для минимизации неквадратичных функций.** Для того чтобы указанный метод можно было применить для минимизации произвольной гладкой функции  $f$ , формулу (10.35) для вычисления коэффициента  $\beta_{n-1}$  преобразуют к виду

$$\beta_{n-1} = \frac{(g^{(n)}, g^{(n)} - g^{(n-1)})}{|g^{(n-1)}|^2} \quad (10.36)$$

или к виду

$$\beta_{n-1} = \frac{|g^{(n)}|^2}{|g^{(n-1)}|^2}. \quad (10.37)$$

Преимущество формул (10.36), (10.37) в том, что они не содержат явным образом матрицу  $A$ .

Минимизацию функции  $f$  методом сопряженных градиентов производят в соответствии с формулами

$$\mathbf{x}^{(n+1)} = \mathbf{x}^{(n)} + \alpha_n \mathbf{p}^{(n)}, \quad n \geq 0, \quad (10.38)$$

$$\mathbf{p}^{(0)} = -\mathbf{g}^{(0)}, \quad \mathbf{p}^{(n)} = -\mathbf{g}^{(n)} + \beta_{n-1} \mathbf{p}^{(n-1)}, \quad n \geq 1, \quad (10.39)$$

$$\varphi_n(\alpha_n) = \min_{\alpha \geq 0} \varphi_n(\alpha), \quad \varphi_n(\alpha) = f(\mathbf{x}^{(n)} + \alpha \mathbf{p}^{(n)}). \quad (10.40)$$

Коэффициенты  $\beta_{n-1}$  вычисляют по одной из формул (10.36), (10.37).

Итерационный процесс здесь уже не оканчивается после конечного числа шагов, а направления  $\mathbf{p}^{(n)}$  не являются, вообще говоря, сопряженными относительно некоторой матрицы.

Решение задач одномерной минимизации (10.40) приходится осуществлять численно. Отметим также то, что часто в методе сопряженных градиентов при  $n = m, 2m, 3m, \dots$  коэффициент  $\beta_{n-1}$  не вычисляют по формулам (10.36), (10.37), а полагают равным нулю. При этом очередной шаг производят фактически методом наискорейшего спуска. Такое "обновление" метода позволяет уменьшить влияние вычислительной погрешности.

Для сильно выпуклой гладкой функции  $f$  при некоторых дополнительных условиях метод сопряженных градиентов обладает высокой сверхлинейной скоростью сходимости. В то же время его трудоемкость невысока и сравнима с трудоемкостью метода наискорейшего спуска. Как показывает вычислительная практика, он незначительно уступает по эффективности квазиньютоновским методам, но предъявляет значительно меньшие требования к используемой памяти ЭВМ. В случае, когда решается задача минимизации функции с очень большим числом переменных, метод сопряженных градиентов, по-видимому, является единственным подходящим универсальным методом.

## § 10.6. Методы минимизации без вычисления производных

**1. Методы прямого поиска. Метод деформируемого многогранника.** Существует большой класс методов минимизации, каждый из которых основан на сравнении значений целевой функции в последовательно вычисляемых пробных точках. Это так называемые *методы прямого поиска*. Обычно они применяются тогда, когда в любой окрестности точки локального минимума целевая функция не является гладкой, а множество точек, в которых она недифференцируема, имеет слишком сложную структуру. К сожалению, методы прямого поиска в большинстве случаев очень неэффективны. Обращаться к ним, по-видимому,

имеет смысл только тогда, когда есть уверенность, что никакие другие подходы к решению задачи минимизации невозможны.

Рассмотрим кратко один из наиболее известных методов прямого поиска — *метод деформируемого многогранника*. Сначала необходимо задать  $m + 1$  точку  $\mathbf{x}_1^{(0)}, \mathbf{x}_2^{(0)}, \dots, \mathbf{x}_{m+1}^{(0)}$  так, чтобы векторы  $\mathbf{x}_2^{(0)} - \mathbf{x}_1^{(0)}, \mathbf{x}_3^{(0)} - \mathbf{x}_1^{(0)}, \dots, \mathbf{x}_{m+1}^{(0)} - \mathbf{x}_1^{(0)}$  были линейно независимы. Тогда эти точки можно интерпретировать как вершины  $m$ -мерного многогранника. Обычно начальный многогранник выбирают правильным.

Опишем очередную  $(n + 1)$ -ю итерацию простейшего варианта метода. Будем предполагать, что точки  $\mathbf{x}_1^{(n)}, \mathbf{x}_2^{(n)}, \dots, \mathbf{x}_{m+1}^{(n)}$  являются вершинами многогранника, полученного на предыдущей итерации, и занумерованы так, что  $f(\mathbf{x}_1^{(n)}) = \min_{1 \leq i \leq m+1} f(\mathbf{x}_i^{(n)})$ ,  $f(\mathbf{x}_{m+1}^{(n)}) = \max_{1 \leq i \leq m+1} f(\mathbf{x}_i^{(n)})$ . Отбрасывают точку  $\mathbf{x}_{m+1}^{(n)}$  как самую неудачную.

Затем вычисляют "центр тяжести" оставшихся точек по формуле  $\mathbf{u}^{(n)} = \frac{1}{m} \sum_{i=1}^m \mathbf{x}_i^{(n)}$  и строят пробную точку  $\mathbf{x}_{\text{пр}}^{(n)} = \mathbf{u}^{(n)} + (\mathbf{u}^{(n)} - \mathbf{x}_{m+1}^{(n)})$ , отразив симметрично вершину  $\mathbf{x}_{m+1}^{(n)}$  относительно точки  $\mathbf{u}^{(n)}$ .

Геометрическая иллюстрация этой операции в случае  $m = 2$  приведена на рис. 10.9, а. Заметим, что в плоском случае роль многогранника играет треугольник.

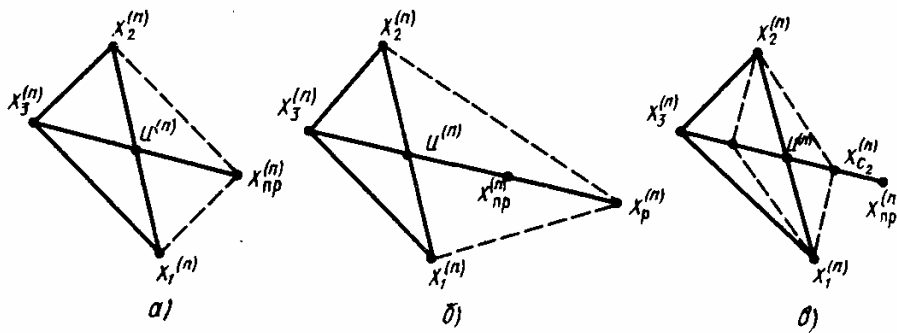


Рис. 10.9

Далее возможны три случая.

**С л у ч а й 1:**  $f(\mathbf{x}_1^{(n)}) \leq f(\mathbf{x}_{\text{пр}}^{(n)}) \leq f(\mathbf{x}_m^{(n)})$ , т. е. пробная точка не привела к уменьшению значения целевой функции, но и не стала "худшей" в наборе  $\mathbf{x}_1^{(n)}, \mathbf{x}_2^{(n)}, \dots, \mathbf{x}_m^{(n)}, \mathbf{x}_{\text{пр}}^{(n)}$ . В этом случае точку признают удовлетворительной и  $\mathbf{x}_{m+1}^{(n)}$  заменяют на  $\mathbf{x}_{\text{пр}}^{(n)}$ .

С л у ч а й 2:  $f(\mathbf{x}_{\text{пр}}^{(n)}) < f(\mathbf{x}_1^{(n)})$ , т. е. выбор пробной точки привел к уменьшению значения целевой функции. Тогда направление отражения считают удачным и делают попытку "растянуть" многогранник в этом направлении с коэффициентом растяжения  $\beta > 1$  (обычно  $2 \leq \beta \leq 3$ ). Находят точку  $\mathbf{x}_p^{(n)} = \mathbf{u}^{(n)} + \beta(\mathbf{u}^{(n)} - \mathbf{x}_{m+1}^{(n)})$ . Если  $f(\mathbf{x}_p^{(n)}) < f(\mathbf{x}_{\text{пр}}^{(n)})$ , то растяжение прошло удачно и точку  $\mathbf{x}_{m+1}^{(n)}$  заменяют на  $\mathbf{x}_p^{(n)}$ . В противном случае растяжение было неудачным и производят замену  $\mathbf{x}_{m+1}^{(n)}$  на  $\mathbf{x}_{\text{пр}}^{(n)}$ . На рис. 10.9, б показано "растяжение" с коэффициентом  $\beta = 2$ .

С л у ч а й 3:  $f(\mathbf{x}_{\text{пр}}^{(n)}) > f(\mathbf{x}_m^{(n)})$ . В этом случае считают, что многогранник следует сжать. Если  $f(\mathbf{x}_{\text{пр}}^{(n)}) > f(\mathbf{x}_{m+1}^{(n)})$ , то вершину  $\mathbf{x}_{m+1}^{(n)}$  заменяют точкой  $\mathbf{x}_{c_1}^{(n)} = \mathbf{u}^{(n)} - \gamma(\mathbf{u}^{(n)} - \mathbf{x}_{m+1}^{(n)})$ . Если же  $f(\mathbf{x}_{\text{пр}}^{(n)}) \leq f(\mathbf{x}_{m+1}^{(n)})$ , то  $\mathbf{x}_{m+1}^{(n)}$  заменяют на  $\mathbf{x}_{c_2}^{(n)} = \mathbf{u}^{(n)} + \gamma(\mathbf{u}^{(n)} - \mathbf{x}_{m+1}^{(n)})$ . Здесь  $0 < \gamma < 1$ ,  $\gamma$  — коэффициент сжатия (обычно  $\gamma = 1/2$ ). На рис. 10.9, в показано "сжатие" с коэффициентом  $\gamma = 1/2$ .

Помимо операций отражения, сжатия и растяжения периодически (после выполнения определенного числа итераций) производят операцию замены текущего многогранника правильным многогранником — так называемое *восстановление*. При восстановлении сохраняются лишь две лучшие точки последнего многогранника. Расстояние между этими точками принимают за длину ребра вновь генерируемого правильного многогранника. Эта операция позволяет ликвидировать излишние деформации, возникающие в ходе итераций.

Известно большое число различных модификаций этого метода. Подробно они описаны в книгах [24], [91]. Там же указаны различные критерии окончания.

**2. Методы минимизации гладких функций, использующие конечно-разностные аппроксимации производных.** Довольно часто в приложениях возникает необходимость в минимизации функций, обладающих достаточным числом производных, которые тем не менее недоступны для прямого вычисления. Например, такая ситуация имеет место тогда, когда значение функции является результатом решения сложной математической задачи. В этом случае приходится применять алгоритмы, использующие лишь вычисляемые в различных точках значения функции  $f$ . Здесь обращение к методам прямого поиска (типа метода деформируемого многогранника), специально разработанным для минимизации негладких функций, вряд ли целесообразно,

так как эти методы не позволяют извлекать никакой выгоды из возможной гладкости функции. Часто существенно лучший результат можно получить, заменив в одном из алгоритмов спуска используемые в нем производные их аппроксимациями в соответствии с формулами численного дифференцирования (см. гл. 12). Например, для производной  $f'_{x_j}$  простейшая аппроксимация такова:

$$\begin{aligned} f'_{x_j}(x_1, x_2, \dots, x_m) &\approx \\ &\approx \frac{1}{h_j} (f(x_1, \dots, x_{j-1}, x_j + h_j, x_{j+1}, \dots, x_m) - f(x_1, x_2, \dots, x_m)). \end{aligned}$$

Подобная модификация алгоритмов не является тривиальной и требует достаточной осторожности в реализации. Это связано с высокой чувствительностью формул численного дифференцирования к ошибкам в вычислении функции (см. § 12.3). Более подробное обсуждение методов минимизации, использующих конечно-разностное аппроксимации производных, можно найти в [24] и [32]. В заключение все же отметим, что конечно-разностные аппроксимации производных используются в алгоритмах минимизации тогда, когда аналитическое вычисление производных невозможно. Если же производные можно вычислить аналитически, то усилия, потраченные на такое вычисление, как правило, окупаются.

## § 10.7. Дополнительные замечания

1. **Задача о наименьших квадратах.** Среди задач безусловной минимизации особое место занимает задача минимизации функций вида

$$\Phi(\mathbf{x}) = \sum_{j=1}^N f_j(\mathbf{x})^2, \quad (10.41)$$

где  $f_1(\mathbf{x}), \dots, f_N(\mathbf{x})$  — некоторые функции  $m$  переменных.

Необходимость в минимизации таких функций возникает, например, при использовании метода наименьших квадратов для решения задачи аппроксимации функции (см. гл. 11) либо для решения проблемы идентификации математической модели по данным эксперимента. К поиску точки минимума функции вида (10.41) сводится и задача решения системы нелинейных уравнений

$$f_j(\mathbf{x}) = 0 \quad (j = 1, 2, \dots, N) \quad (10.42)$$

(см. гл. 7). Действительно, если решение  $\bar{\mathbf{x}}$  системы (10.42) существует, то оно совпадает с точкой глобального минимума функции  $\Phi$ , причем  $\Phi(\bar{\mathbf{x}}) = 0$ .

Для минимизации функции (10.41) в принципе можно применить любой из универсальных методов минимизации. Однако, как правило, этого не делают, а используют алгоритмы, специально разработанные для решения задачи о наименьших квадратах. Достаточно подробное их обсуждение можно найти, например, в [32].

2. Естественно, что в данной книге содержится лишь краткое введение в методы решения задач безусловной минимизации. Более подробное изложение можно найти, например, в [6], [18], [24], [32], [64], [66], [76], [91] и др.

3. **Задачи условной минимизации.** Множество  $X$ , на котором минимизируется функция  $f$ , часто задается с помощью системы неравенств вида

$$g_i(x_1, x_2, \dots, x_m) \geq 0, \quad i = 1, 2, \dots, k$$

Если целевая функция  $f$  и задающие множество  $X$  функции  $g_i$  линейны, то задачу минимизации называют *задачей линейного программирования*. Если же хотя бы одна из этих функций нелинейна, то говорят о *задаче нелинейного программирования*.

Обсуждение методов решения задач условной минимизации при всей их важности выходит за рамки данной книги. Укажем, например, на книги [18], [24], [76], [91], содержащие достаточно подробное и доступное введение в соответствующие методы.

4. Особый класс задач составляют так называемые *задачи дискретной минимизации*. В этих задачах множество  $X$ , на котором минимизируется функция  $f$ , является конечным или счетным. Часто  $X$  — множество точек с целочисленными координатами, удовлетворяющими некоторым ограничениям. Методы решения таких задач описаны, например, в [76].

5. Авторы рекомендуют обратить внимание на книгу [24], в особенности на ее последние главы ("Моделирование", "Практические вопросы" и "Вопросы и ответы"). В них содержится большое число весьма интересных замечаний, полезных рекомендаций и советов для широкого круга специалистов, заинтересованных в решении практических задач минимизации.



## Глава 11

### ПРИБЛИЖЕНИЕ ФУНКЦИЙ И СМЕЖНЫЕ ВОПРОСЫ

В этой главе рассматриваются наиболее важные и часто встречающиеся в приложениях методы приближения функций одной переменной. Значительное внимание уделено интерполяции, причем рассматривается интерполяция не только алгебраическими многочленами, но и тригонометрическими многочленами, а также интерполяция сплайнами. Довольно подробно обсуждается метод наименьших квадратов, широко используемый в практике инженерных расчетов. Дается понятие о наилучшем равномерном приближении и дробно-рациональных аппроксимациях.

В главу включены также некоторые вопросы вычислительной математики, имеющие непосредственное отношение к методам аппроксимации (приближения) функций. Это конечные и разделенные разности, многочлены Чебышева, быстрое дискретное преобразование Фурье.

#### § 11.1. Постановка задачи приближения функций

Вычисление значения функции  $y = f(x)$  — одна из тех задач, с которой постоянно на практике приходится сталкиваться. Естественно, что при решении на ЭВМ серьезных задач желательно иметь быстрые и надежные алгоритмы вычисления значений используемых функций. Для элементарных, а также для основных специальных функций такие алгоритмы разработаны, реализованы в виде стандартных программ и включены в математическое обеспечение ЭВМ. Однако в расчетах нередко используются и другие функции, непосредственное вычисление которых затруднено либо приводит к слишком большим затратам машинного времени. Укажем на некоторые типичные ситуации.

1. Функция  $f$  задана таблицей своих значений:

$$y_i = f(x_i), \quad (i = 0, 1, 2, \dots, n), \quad (11.1)$$

а вычисления производятся в точках  $x$ , не совпадающих с табличными.

2. Непосредственное вычисление значения  $y = f(x)$  связано с проведением сложных расчетов и приводит к значительным затратам машинного времени, которые могут оказаться неприемлемыми, если функция  $f$  вычисляется многократно.

3. При заданном значении  $x$  значение  $f(x)$  может быть найдено из эксперимента. Ясно, что такой способ "вычисления" в большинстве случаев нельзя использовать в вычислительных алгоритмах, так как он связан с необходимостью прерывания вычислительного процесса для проведения эксперимента<sup>1</sup>. В этой ситуации экспериментальные данные получают до начала вычислений на ЭВМ. Нередко они представляют собой таблицу типа (11.1) с тем отличием, что табличные значения  $y_i^*$  отличаются от "истинных" значений  $y_i$ , так как заведомо содержат ошибки эксперимента.

Возникающие проблемы нередко удается решить следующим образом. Функцию  $f(x)$  приближенно заменяют другой функцией  $g(x)$ , вычисляемые значения которой и принимают за приближенные значения функции  $f$ . Конечно, такая замена оправдана лишь тогда, когда значения  $g(x)$  вычисляются быстро и надежно, а погрешность приближения  $f(x) - g(x)$  достаточно мала. Обсудим кратко некоторые вопросы, с которыми в каждом конкретном случае приходится сталкиваться при выборе постановки задачи приближения и метода ее решения.

1<sup>0</sup>. Необходимо решить, какую информацию о функции  $f$  можно использовать как входные данные для вычисления приближения  $g$ . Например, часто известна или может быть получена таблица значений функции вида (11.1), а иногда — и таблица ее производных. В некоторых случаях можно использовать информацию о значениях функции на всем отрезке  $[a, b]$ .

2<sup>0</sup>. Полезно иметь некоторую дополнительную априорную информацию об аппроксимируемой функции. Часто она бывает качественного характера, например известно, что функция  $f$  "достаточно гладкая" ("плавно меняющаяся"), периодическая, монотонная, четная и т. п. Иногда удается получить некоторые количественные характеристики функции  $f$ , например, бывают известны верхние оценки для максимума

---

<sup>1</sup> Правда, в некоторых алгоритмах такое прерывание естественно, например если ЭВМ используется для управления технологическим процессом, сложной технической системой или включена в систему обработки и планирования физического эксперимента.

модуля некоторых ее производных, величина периода, оценка уровня погрешности в заданных значениях.

30. Знание свойств функции  $f$  позволяет осознанно выбирать класс  $G$  аппроксимирующих функций. Часто такой класс представляет собой параметрическое семейство функций вида  $y = g(x, a) = g(x, a_0, a_1, \dots, a_m)$  и выбор конкретной аппроксимирующей функции  $g$  осуществляется с помощью выбора параметров  $a_0, a_1, \dots, a_m$ . Широко используются классы функций вида

$$\Phi_m(x) = a_0\varphi_0(x) + a_1\varphi_1(x) + \dots + a_m\varphi_m(x), \quad (11.2)$$

являющихся линейными комбинациями фиксированного набора некоторых базисных функций  $\varphi_0(x), \varphi_1(x), \dots, \varphi_m(x)$ . Функцию  $\Phi_m(x)$  часто называют *обобщенным многочленом* по системе функций  $\varphi_0, \varphi_1, \dots, \varphi_m$ , а число  $m$  — его *степенью*.

Если в качестве базисных функций берутся степенные функции  $\varphi_k(x) = x^k$ , то возникает задача приближения алгебраическими многочленами

$$P_m(x) = a_0 + a_1x + \dots + a_mx^m. \quad (11.3)$$

Отметим, что методы приближения функций алгебраическими многочленами играют важную роль в численном анализе и наиболее глубоко разработаны. Одна из причин этого состоит в том, что многочлены (11.3) легко вычисляются, без труда дифференцируются и интегрируются.

Тригонометрические многочлены

$$S_m(x) = \alpha_0 + \sum_{1 \leq k \leq m/2} (\alpha_k \cos 2\pi kx + \beta_k \sin 2\pi kx), \quad (11.4)$$

часто используемые для аппроксимации периодических на отрезке  $[0, 1]$  функций, также могут быть записаны в виде (11.2), если в качестве базисных функций выбрать функции  $\varphi_0(x) = 1$ ,  $\varphi_1(x) = \cos 2\pi x$ ,  $\varphi_2(x) = \sin 2\pi x$ ,  $\varphi_3(x) = \cos 4\pi x$ ,  $\varphi_4(x) = \sin 4\pi x$ , ... . Используя формулу Эйлера  $\exp \{iy\} = \cos y + i \sin y$ , можно записать тригонометрический многочлен (11.4) в виде

$$S_m(x) = \sum_{-m/2 \leq k \leq m/2} a_k \exp \{2\pi i kx\}, \quad (11.5)$$

что соответствует выбору базисных функций  $\varphi_k(x) = \exp \{2\pi i kx\}$ ,  $-m/2 \leq k \leq m/2$ .

Используются также и некоторые нелинейные комбинации функций, отличные от (11.2). Например, в ряде случаев эффективным является использование класса дробно-рациональных функций

$$\frac{a_0 + a_1 x + \dots + a_n x^n}{1 + b_1 x + \dots + b_k x^k}.$$

Выбор класса  $G$  аппроксимирующих функций осуществляется с учетом того, насколько хорошо может быть приближена функция  $f$  функциями из этого класса.

4°. Необходим критерий выбора в классе  $G$  конкретной аппроксимирующей функции  $g$ , являющейся в смысле этого критерия наилучшим приближением к  $f$ . Например, требование совпадения функции  $g$  с функцией  $f$  в некоторых фиксированных точках приводит к задаче интерполяции. Другой распространенный критерий — требование минимизации среднеквадратичного отклонения — лежит в основе метода наименьших квадратов. Существует большое число других критериев, естественных в конкретных прикладных проблемах.

5°. Важно понимать, что решение указанных выше вопросов тесно связано с тем, как мы собираемся использовать приближение  $g$  и какая точность нам нужна.

**З а м е ч а н и е.** Задачу выбора в классе  $G$  конкретной приближающей функции можно рассматривать как задачу идентификации (см. § 1.1), если интерпретировать функцию  $y = g(x, a)$  как математическую модель реальной функциональной зависимости  $y = f(x)$ .

## § 11.2. Интерполяция обобщенными многочленами

**1. Постановка задачи интерполяции.** Пусть в точках  $x_0, x_1, \dots, x_n$ , расположенных на отрезке  $[a, b]$  и попарно различных, задана таблица (11.1) значений некоторой функции  $f$ . Задача интерполяции состоит в построении функции  $g$ , удовлетворяющей условию

$$g(x_i) = y_i \quad (i = 0, 1, \dots, n). \quad (11.6)$$

Другими словами, ставится задача о построении функции  $g$ , график которой проходит через заданные точки  $(x_i, y_i)$  (рис. 11.1). Указанный способ приближения функций принято называть *интерполяцией* (или *интерполированием*), а точки  $x_i$  — *узлами интерполяции*.

Нетрудно видеть, что выбор функции  $g$  неоднозначен, так как по заданной таблице можно построить бесконечно много интерполирующих функ-

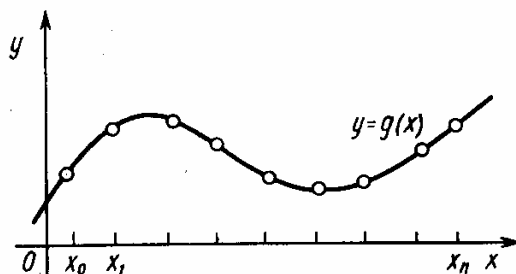


Рис. 11.1

ций. На практике, как правило, функцию  $g$  выбирают из достаточно узкого класса  $G$  функций, в котором единственность выбора гарантируется.

2. **Экстраполяция.** Пусть  $x_{\min}$  и  $x_{\max}$  — минимальный и максимальный из узлов интерполяции. В случае, когда интерполяция используется для вычисления приближенного значения функции  $f$  в точке  $x$ , не принадлежащей отрезку  $[x_{\min}, x_{\max}]$  (*отрезку наблюдения*), принято говорить о том, что осуществляется *экстраполяция*. Этот метод приближения часто используют с целью прогнозирования характера протекания тех или иных процессов при значениях параметров  $x$ , выходящих за пределы отрезка наблюдения. Заметим, что надежность такого прогноза при значениях  $x$ , удаленных на значительное расстояние от отрезка  $[x_{\min}, x_{\max}]$ , как правило, невелика.

3. **Задача интерполяции обобщенными многочленами.** Рассмотрим более подробно задачу интерполяции обобщенными многочленами  $\Phi_m(x)$  вида (11.2). Назовем обобщенный многочлен  $\Phi_m(x)$  *интерполяционным*, если он удовлетворяет условию

$$\Phi_m(x_i) = y_i \quad (i = 0, 1, \dots, n), \quad (11.6)$$

или, что то же самое, системе линейных алгебраических уравнений

[illegible]

относительно коэффициентов  $a_0, a_1, \dots, a_m$ .

Заметим, что систему уравнений (11.7) можно записать в следующем виде:

$$P\mathbf{a} = \mathbf{y}, \quad (11.8)$$

где

$$P = \begin{bmatrix} \varphi_0(x_0) & \varphi_1(x_0) & \dots & \varphi_m(x_0) \\ \varphi_0(x_1) & \varphi_1(x_1) & \dots & \varphi_m(x_1) \\ \dots & \dots & \dots & \dots \\ \varphi_0(x_n) & \varphi_1(x_n) & \dots & \varphi_m(x_n) \end{bmatrix}, \quad a = \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_m \end{bmatrix}, \quad y = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_n \end{bmatrix}. \quad (11.9)$$

Введем векторы  $\varphi_j = (\varphi_j(x_0), \varphi_j(x_1), \dots, \varphi_j(x_n))^T$ ,  $j = 0, 1, \dots, m$ . Будем говорить, что система функций  $\varphi_0, \varphi_1, \dots, \varphi_m$  линейно зависима в точках  $x_0, x_1, \dots, x_n$ , если один из векторов  $\varphi_j$  системы  $\varphi_0, \varphi_1, \dots, \varphi_m$

может быть представлен в виде линейной комбинации остальных векторов этой системы:

$$\varphi_j = \sum_{\substack{k=0 \\ k \neq j}}^m \alpha_k \varphi_k. \quad (11.10)$$

В противном случае систему функций  $\varphi_0, \varphi_1, \dots, \varphi_m$  будем называть *линейно независимой в точках*  $x_0, x_1, \dots, x_n$ .

**Пример 11.1.** Покажем, что при  $m \leq n$  система функций  $1, x, x^2, \dots, x^m$  линейно независима в точках  $x_0, x_1, \dots, x_n$ , если они попарно различны.

Допустим противное. Тогда справедливо равенство (11.10), которое в данном случае (при  $\varphi_k = (x_0^k, x_1^k, \dots, x_n^k)^T$ ) принимает вид

$$x_i^j = \sum_{\substack{k=0 \\ k \neq j}}^m \alpha_k x_i^k \quad (i = 0, 1, \dots, n). \quad (11.11)$$

Полагая  $\alpha_j = -1$ , получаем, что многочлен  $P_m(x) = \sum_{k=0}^m \alpha_k x^k$  степени<sup>1</sup>  $m$  обращается в ноль в точках  $x_0, x_1, \dots, x_n$ , число которых равно  $n + 1$  и, следовательно, больше  $m$ . Однако в силу основной теоремы алгебры многочлен степени  $m$  тождественно не равный нулю, не может иметь более  $m$  корней. Полученное противоречие доказывает линейную независимость рассматриваемой системы функций.

Рассмотрим *матрицу Грама*<sup>2</sup> системы функций  $\varphi_0, \varphi_1, \dots, \varphi_m$ , имеющую вид

$$\Gamma = P^* P = \begin{bmatrix} (\varphi_0, \varphi_0) & (\varphi_1, \varphi_0) & \dots & (\varphi_m, \varphi_0) \\ (\varphi_0, \varphi_1) & (\varphi_1, \varphi_1) & \dots & (\varphi_m, \varphi_1) \\ \dots & \dots & \dots & \dots \\ (\varphi_0, \varphi_m) & (\varphi_1, \varphi_m) & \dots & (\varphi_m, \varphi_m) \end{bmatrix}. \quad (11.12)$$

Здесь в случае, когда функции  $\varphi_j$  могут принимать комплексные значения, под  $P^*$  понимается сопряженная к  $P$  матрица, а элементы  $\gamma_{jk}$  матрицы Грама вычисляются по формуле

<sup>1</sup> В данной главе для упрощения формулировок будем говорить, что многочлен  $P_m$  имеет степень  $m$  даже в случае, когда  $a_m = 0$ , т. е. фактическая его степень меньше  $m$ .

<sup>2</sup> Иорген Педерсен Грам (1850—1916) — датский математик.

$$\gamma_{jk} = (\varphi_k, \varphi_j) = \sum_{i=0}^n \varphi_k(x_i) \overline{\varphi_j(x_i)}, \quad (11.13)$$

Если же функции  $\varphi_j$  принимают только вещественные значения, то  $P^* = P^T$  и элементы матрицы Грама вычисляются по формуле

$$\gamma_{jk} = (\varphi_k, \varphi_j) = \sum_{i=0}^n \varphi_k(x_i) \varphi_j(x_i). \quad (11.14)$$

Определитель матрицы Грама  $\det \Gamma$  принято называть *определителем Грама*.

Как следует из курса линейной алгебры, справедлив следующий результат.

**Теорема 11.1.** Система функций  $\varphi_0, \varphi_1, \dots, \varphi_n$  является линейно независимой в точках  $x_0, x_1, \dots, x_n$  тогда и только тогда, когда  $m \leq n$  и определитель Грама  $\det \Gamma$  отличен от нуля.

Известно, что при  $m > n$  система функций  $\varphi_0, \varphi_1, \dots, \varphi_m$  линейно зависима в точках  $x_0, x_1, \dots, x_n$ . Отсюда вытекает неединственность решения  $\mathbf{a}$  системы (11.8) (если оно существует). Действительно, в этом случае справедливо представление (11.10) и вместе с вектором  $\mathbf{a}$  решением системы (11.8) является вектор  $\mathbf{a}' = \mathbf{a} + t\Delta\mathbf{a}$ , где  $\Delta\mathbf{a} = (\alpha_0, \alpha_1, \dots, \alpha_{j-1}, -1, \alpha_{j+1}, \dots, \alpha_m)^T$ , а  $t$  — любое число. Если же  $m < n$ , то решение системы (11.8) существует не для всякой правой части  $\mathbf{y}$ .

В силу указанных причин при интерполяции обобщенными многочленами число параметров  $m + 1$  обычно берут равным числу  $n + 1$  заданных точек. В этом случае  $P$  — квадратная матрица и для того, чтобы система (11.8) была однозначно разрешима при любой правой части  $\mathbf{y}$ , необходимо и достаточно, чтобы определитель матрицы  $P$  был отличен от нуля. В свою очередь при  $m = n$  это условие в силу равенства  $\det \Gamma = \det P^* \det P = |\det P|^2$  и теоремы 11.1 дает следующий результат.

**Теорема 11.2.** Если  $m = n$ , то решение задачи интерполяции обобщенным многочленом (11.2) существует и единственно при любом наборе данных  $y_0, y_1, \dots, y_n$  тогда и только тогда, когда система функций  $\varphi_0, \varphi_1, \dots, \varphi_n$  линейно независима в точках  $x_0, x_1, \dots, x_n$ .

Назовем систему функций  $\varphi_0, \varphi_1, \dots, \varphi_m$  ортогональной на множестве точек  $x_0, x_1, \dots, x_n$ , если  $(\varphi_k, \varphi_j) = 0$  при  $k \neq j$  и  $(\varphi_k, \varphi_j) \neq 0$  при  $k = j$  для всех  $k = 0, 1, \dots, m$ ;  $j = 0, 1, \dots, m$ . Очевидно, что для ортогональной на множестве  $x_0, x_1, \dots, x_n$  системы функций матрица Грама диагональна, а определитель Грама отличен от нуля. Поэтому всякая ортогональная на множестве точек  $x_0, x_1, \dots, x_n$  система функций заведомо является линейно независимой в этих точках.

**Пример 11.2.** Покажем, что система функций  $\varphi_0, \varphi_1, \dots, \varphi_{N-1}$ , где  $\varphi_k(x) = \exp \{2\pi i k x\}$ , ортогональна на множестве точек  $x_l = l/N, l = 0, 1, \dots, N-1$ . Здесь  $i$  — мнимая единица.

Для доказательства ортогональности рассматриваемой системы функций достаточно установить, что справедливо равенство

$$(\varphi_k, \varphi_j) = N\delta_{kj} \quad (k = 0, 1, \dots, N-1; j = 0, 1, \dots, N-1), \quad (11.15)$$

где  $\delta_{kj} = 0$  при  $k \neq j$  и  $\delta_{kj} = 1$  при  $k = j$ . Введем обозначение  $\omega = \exp \{2\pi i/N\}$ . Тогда  $\varphi_k(x_l) = \exp \{2\pi i k l/N\} = \omega^{kl}$  и согласно формуле (11.13) имеем

$$(\varphi_k, \varphi_j) = \sum_{l=0}^{N-1} \omega^{kl} \omega^{-jl} = \sum_{l=0}^{N-1} [\omega^{k-j}]^l. \quad (11.16)$$

При  $k = j$  правая часть равенства (11.16), очевидно, равна  $N$ . При  $k \neq j$ , используя формулу суммы членов геометрической прогрессии и равенство  $\omega^{(k-j)N} = \exp \{2\pi i(k-j)\} = 1$ , имеем

$$(\varphi_k, \varphi_j) = (1 - [\omega^{k-j}]^N)/(1 - \omega^{k-j}) = 0.$$

Таким образом, равенство (11.15), а вместе с ним и ортогональность системы функций  $\varphi_k(x) = \exp \{2\pi i k x\}$  доказаны.

В случае, когда система функций  $\varphi_0, \varphi_1, \dots, \varphi_n$  ортогональна на множестве точек  $x_0, x_1, \dots, x_n$ , решение задачи интерполяции не представляет затруднений. Действительно, система уравнений (11.8) после умножения на матрицу  $P^*$  преобразуется к виду

$$\Gamma a = b, \quad b = P^* y. \quad (11.17)$$

Заметим, что элементы вектора  $b = (b_0, b_1, \dots, b_m)^T$  вычисляются по формуле

$$b_j = (y, \varphi_j) = \sum_{l=0}^n y_l \overline{\varphi_j(x_l)}, \quad j = 0, 1, \dots, m. \quad (11.18)$$

Так как матрица  $\Gamma$  диагональна, то решение системы (11.17) находится в явном виде:

$$a_j = \frac{(y, \varphi_j)}{(\varphi_j, \varphi_j)}, \quad j = 0, 1, \dots, m. \quad (11.19)$$



## Многочлен Лагранжа

$$P_n(x_i) = y_i \quad (i = 0, 1, \dots, n). \quad (11.20)$$
[illegible]
$$\begin{vmatrix} 1 & x_0 & x_0^2 & \dots & x_0^n \\ 1 & x_1 & x_1^2 & \dots & x_1^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \dots & x_n^n \end{vmatrix} = \prod_{0 \leq j < i \leq n} (x_i - x_j)$$

**З а м е ч а н и е.** На практике система (11.21) никогда не используется для вычисления коэффициентов интерполяционного многочле-

300

на. Дело в том, что часто она является плохо обусловленной. Кроме того, существуют различные удобные явные формы записи интерполяционного многочлена, которые и применяются при интерполяции. Наконец, в большинстве приложений интерполяционного многочлена явное вычисление коэффициентов  $a_k$  не нужно.

**2. Многочлен Лагранжа.** Приведем одну из форм записи интерполяционного многочлена — *многочлен Лагранжа*

$$L_n(x) = \sum_{j=0}^n y_j l_{nj}(x). \quad (11.22)$$

Здесь

$$l_{nj}(x) = \prod_{\substack{k=1 \\ k \neq j}}^n \frac{x - x_k}{x_j - x_k} = \frac{(x-x_0)(x-x_1)\dots(x-x_{j-1})(x-x_{j+1})\dots(x-x_n)}{(x_j-x_0)(x_j-x_1)\dots(x_j-x_{j-1})(x_j-x_{j+1})\dots(x_j-x_n)}.$$

Как нетрудно видеть,  $l_{nj}(x)$  представляет собой многочлен степени  $n$ , удовлетворяющий условию

$$l_{nj}(x_i) = \begin{cases} 1 & \text{при } i = j, \\ 0 & \text{при } i \neq j. \end{cases}$$

Таким образом, степень многочлена  $L_n$  равна  $n$  и при  $x = x_i$  в сумме (11.22) обращаются в ноль все слагаемые, кроме слагаемого с номером  $j = i$ , равного  $y_i$ . Поэтому многочлен Лагранжа (11.22) действительно является интерполяционным.

**З а м е ч а н и е 1.** Запись интерполяционного многочлена в форме Лагранжа (11.22) можно рассматривать как его запись в виде обобщенного многочлена (11.2) по системе функций  $\varphi_k(x) = l_{nk}(x)$ ,  $k = 0, 1, \dots, n$ .

**З а м е ч а н и е 2.** Как правило, интерполяционный многочлен Лагранжа используется так, что нет необходимости его преобразования к каноническому виду  $L_n(x) = \sum_{k=0}^n a_k x^k$ . Более того, часто такое преобразование нежелательно.

В инженерной практике наиболее часто используется интерполяция многочленами первой, второй и третьей степени (*линейная, квадратичная и кубическая интерполяции*). Приведем соответствующие формулы для записи многочленов Лагранжа первой и второй степени:

$$L_1(x) = y_0 \frac{x - x_1}{x_0 - x_1} + y_1 \frac{x - x_0}{x_1 - x_0}, \quad (11.23)$$

$$L_2(x) = y_0 \frac{(x - x_1)(x - x_2)}{(x_0 - x_1)(x_0 - x_2)} + y_1 \frac{(x - x_0)(x - x_2)}{(x_1 - x_0)(x_1 - x_2)} + y_2 \frac{(x - x_0)(x - x_1)}{(x_2 - x_0)(x_2 - x_1)}. \quad (11.24)$$

**Пример 11.3.** Пусть задана таблица значений функции  $y = \ln x$ :

Т а б л и ц а 11.1

$x$	1.0	1.1	1.2	1.3	1.4
$y$	0.000000	0.095310	0.182322	0.262364	0.336472

Для приближенного вычисления значения  $\ln(1.23)$  воспользуемся линейной и квадратичной интерполяцией.

Возьмем  $x_0 = 1.2$ ,  $x_1 = 1.3$ . Вычисление по формуле (11.23) дает значение  $\ln(1.23) \approx L_1(1.23) \approx 0.206335$ .

Для применения квадратичной интерполяции возьмем  $x_0 = 1.1$ ,  $x_1 = 1.2$ ,  $x_2 = 1.3$  — три ближайших к точке  $x = 1.23$  узла. Вычисляя по формуле (11.24), имеем  $\ln(1.23) \approx L_2(1.23) \approx 0.207066$ .

Заметим, что пока нам не известна погрешность полученных приближенных значений.

#### § 11.4. Погрешность интерполяции

Приведем без доказательства наиболее известную теорему о погрешности интерполяции.

**Теорема 11.4.** Пусть функция  $f$  дифференцируема  $n + 1$  раз на отрезке  $[a, b]$ , содержащем узлы интерполяции  $x_i$ ,  $i = 0, 1, \dots, n$ . Тогда для погрешности интерполяции в точке  $x \in [a, b]$  справедливо равенство

$$f(x) - P_n(x) = \frac{f^{(n+1)}(\xi)}{(n+1)!} \omega_{n+1}(x), \quad (11.25)$$

в котором  $\omega_{n+1}(x) = (x - x_0)(x - x_1)\dots(x - x_n)$ , а  $\xi$  — некоторая точка, принадлежащая интервалу  $(a, b)$ .

Основное неудобство в использовании этой теоремы состоит в том, что входящая в формулу (11.25) для погрешности точка  $\xi$  неизвестна. Поэтому чаще используется не сама теорема, а ее следствие.

**С л е д с т в и е.** В условиях теоремы 11.4 справедлива оценка погрешности интерполяции в точке  $x \in [a, b]$ , имеющая вид

$$|f(x) - P_n(x)| \leq \frac{M_{n+1}}{(n+1)!} |\omega_{n+1}(x)|, \quad (11.26)$$

а также оценка максимума модуля погрешности интерполяции на отрезке  $[a, b]$ , имеющая вид

$$\max_{[a, b]} |f(x) - P_n(x)| \leq \frac{M_{n+1}}{(n+1)!} \max_{[a, b]} |\omega_{n+1}(x)|. \quad (11.27)$$

Здесь  $M_{n+1} = \max_{[a, b]} |f^{(n+1)}(x)|$ .

**Пример 11.4.** Оценим погрешность приближений к  $\ln$  (1.23), полученных в примере 11.3 с помощью интерполяции многочленами первой и второй степени. В этих случаях неравенство (11.26) примет вид

$$|f(x) - L_1(x)| \leq \frac{M_2}{2} |(x-x_0)(x-x_1)|, \quad (11.28)$$

$$|f(x) - L_2(x)| \leq \frac{M_3}{6} |(x-x_0)(x-x_1)(x-x_2)|. \quad (11.29)$$

Заметим, что для  $f(x) = \ln(x)$  имеем  $f^{(2)}(x) = -\frac{1}{x^2}$  и  $f^{(3)}(x) = \frac{2}{x^3}$ . Поэтому здесь  $M_2 = \max_{[1.2, 1.3]} |f^{(2)}(x)| = \frac{1}{1.2^2} \approx 0.69$  и  $M_3 = \max_{[1.1, 1.3]} |f^{(3)}(x)| = \frac{2}{1.1^3} \approx 1.5$ . Тогда в силу неравенств (11.28) и (11.29) получаем следующие оценки погрешности:

$$\varepsilon_1 = |\ln(1.23) - L_1(1.23)| \lesssim \frac{0.69}{2} |(1.23-1.2)(1.23-1.3)| \approx 7.3 \cdot 10^{-4},$$

$$\varepsilon_2 = |\ln(1.23) - L_2(1.23)| \lesssim \frac{1.5}{6} |(1.23-1.1)(1.23-1.2)(1.23-1.3)| \approx 6.9 \cdot 10^{-5}.$$

Если на отрезке  $[a, b]$  производная  $f^{(n+1)}$  меняется слабо, то величина абсолютной погрешности  $|f(x) - P_n(x)|$  почти полностью определяется значением функции  $\omega_{n+1}(x)$ . Представление о типичном характере поведения этой функции можно получить из рис. 11.2.

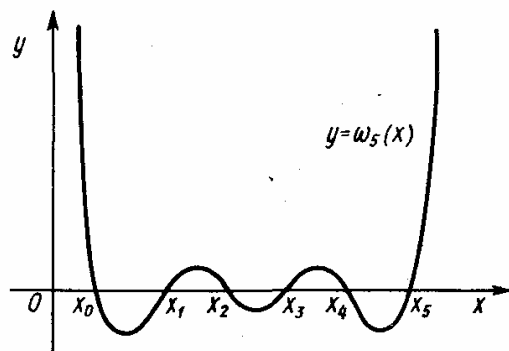


Рис. 11.2

Обратим внимание на то, что при выходе аргумента  $x$  за пределы отрезка наблюдения  $[x_{\min}, x_{\max}]$  значение  $|\omega_{n+1}(x)|$  быстро становится очень большим. Это объясняет ненадежность экстраполяции функции для значений аргумента, удаленных от отрезка наблюдения.

Пусть теперь  $x_0 < x_1 < \dots < x_n$  и пусть  $h_i = x_i - x_{i-1}$  —  $i$ -й шаг таблицы, а  $h_{\max} = \max_{1 \leq i \leq n} h_i$ . Несколько

огрубляя оценку (11.27), можно получить следующее неравенство:

$$\max_{[x_0, x_n]} |f(x) - P_n(x)| \leq \frac{M_{n+1}}{4(n+1)} h_{\max}^{n+1}. \quad (11.30)$$

Оно позволяет утверждать, что для достаточно гладкой функции  $f$  при фиксированной степени интерполяционного многочлена погрешность интерполяции на отрезке  $[x_0, x_n]$  при  $h_{\max} \rightarrow 0$  стремится к нулю не медленнее, чем некоторая величина, пропорциональная  $h_{\max}^{n+1}$ . Этот факт принято формулировать так: интерполяция многочленом степени  $n$  имеет  $(n+1)$ -й порядок точности относительно  $h_{\max}$ . В частности, линейная и квадратичная интерполяции имеют второй и третий порядки точности соответственно.

## § 11.5. Интерполяция с кратными узлами

**1. Интерполяционный многочлен с кратными узлами.** Иногда в узлах  $x_i$  ( $i = 0, 1, \dots, m$ ) бывают заданы не только значения  $y_i = f(x_i)$  функции  $f$ , но и значения ее производных  $y'_i = f'(x_i)$ ,  $y''_i = f''(x_i)$ , ...,  $y_i^{(k_i-1)} = f^{(k_i-1)}(x_i)$  до некоторого порядка  $k_i - 1$ . В этом случае узел  $x_i$  называют *кратным*, а число  $k_i$ , равное количеству заданных значений, — *кратностью узла*. Пусть  $n = k_0 + k_1 + \dots + k_m - 1$ . Можно доказать, что существует единственный многочлен  $P_n(x)$  степени  $n$ , удовлетворяющий условиям

$$P_n(x_i) = y_i, \quad P'_n(x_i) = y'_i, \quad \dots, \quad P_n^{(k_i-1)}(x_i) = y_i^{(k_i-1)}$$

для всех  $i = 0, 1, \dots, m$ . Этот многочлен называют *интерполяционным многочленом с кратными узлами*. Можно указать и явную формулу его записи, аналогичную форме Лагранжа (11.22). Мы этого делать не будем и отметим лишь два важных частных случая.

1<sup>0</sup>. Пусть на концах отрезка  $[x_0, x_1]$  заданы значения  $y_0, y_1, y'_0, y'_1$ . Тогда  $m = 1, k_0 = 2, k_1 = 2, n = 3$  и интерполяционный многочлен  $P_3(x)$ , удовлетворяющий условиям  $P_3(x_0) = y_0, P'_3(x_0) = y'_0, P_3(x_1) = y_1, P'_3(x_1) = y'_1$ , может быть представлен (что проверяется непосредственно) в следующем виде:

$$P_3(x) = y_0 \frac{(x_1 - x)^2(2(x - x_0) + h)}{h^3} + y'_0 \frac{(x_1 - x)^2(x - x_0)}{h^2} + \\ + y_1 \frac{(x - x_0)^2(2(x_1 - x) + h)}{h^3} + y'_1 \frac{(x - x_0)^2(x - x_1)}{h^2}, \quad (11.31)$$

где  $h = x_1 - x_0$ . Многочлен (11.31) принято называть *кубическим интерполяционным многочленом Эрмита*<sup>1</sup>.

2<sup>0</sup>. Пусть в точке  $x_0$  заданы значения  $y_0, y'_0, \dots, y_0^{(n)}$ . Тогда многочлен  $P_n(x)$ , удовлетворяющий условиям  $P_n(x_0) = y_0, P'_n(x_0) = y'_0, \dots, P_n^{(n)}(x_0) = y_0^{(n)}$  представляется в виде

$$P_n(x) = \sum_{k=0}^n y_0^{(k)} \frac{(x - x_0)^k}{k!}. \quad (11.32)$$

Как нетрудно видеть, многочлен  $P_n(x)$  представляет собой отрезок ряда Тейлора. Таким образом, формула Тейлора дает решение задачи интерполяции<sup>2</sup> с одним узлом кратности  $n + 1$ .

## 2. Погрешность интерполяции с кратными узлами.

**Теорема 11.5.** Пусть функция  $f$  дифференцируема  $n + 1$  раз на отрезке  $[a, b]$ , содержащем узлы интерполяции  $x_i$  ( $i = 0, 1, \dots, m$ ). Тогда для погрешности интерполяции с кратными узлами в точке  $x \in [a, b]$  справедливы равенство (11.25) и неравенства (11.26), (11.27), в которых  $\omega_{n+1}(x) = (x - x_0)^{k_0}(x - x_1)^{k_1} \dots (x - x_m)^{k_m}$ , а  $\xi$  — некоторая точка, принадлежащая интервалу  $(a, b)$ .

Для формулы Тейлора ( $m = 0, k_0 = n + 1$ ) теорема 11.5 дает известную формулу остаточного члена в форме Лагранжа. Для кубического

<sup>1</sup> Шарль Эрмит (1822—1901) — французский математик.

<sup>2</sup> Заметим, что в действительности с ее помощью осуществляется экстраполяция.

многочлена Эрмита ( $m = 1$ ,  $k_0 = 2$ ,  $k_1 = 2$ ) неравенство (11.27) приводит к следующей оценке погрешности:

$$\max_{[x_0, x_1]} |f(x) - P_3(x)| \leq \frac{M_4}{384} h^4. \quad (11.33)$$

Здесь учтено то, что максимум функции  $\omega_4(x) = (x - x_0)^2(x - x_1)^2$  на отрезке  $[x_0, x_1]$  достигается в точке  $x = (x_0 + x_1)/2$  и равен  $h^4/16$ .

## § 11.6. Минимизация оценки погрешности интерполяции. Многочлены Чебышева

1. **Постановка задачи минимизации оценки погрешности.** Предположим, что значение заданной на отрезке  $[a, b]$  функции  $f$  можно вычислить в произвольной точке  $x$ . Однако по некоторым причинам<sup>1</sup> целесообразнее заменить прямое вычисление функции  $f$  вычислением значений ее интерполяционного многочлена  $P_n$ . Для такой замены необходимо один раз получить таблицу значений функции  $f$  в выбранных на отрезке  $[a, b]$  точках  $x_0, x_1, \dots, x_n$ . При этом естественно стремиться к такому выбору узлов интерполяции, который позволит сделать минимальной величину  $\Delta(P_n) = \max_{[a, b]} |f(x) - P_n(x)|$  — погрешность

интерполяции на отрезке  $[a, b]$ .

Пусть о функции  $f$  известно лишь то, что она непрерывно дифференцируема  $n + 1$  раз на отрезке  $[a, b]$ . Тогда неравенство (11.27) дает верхнюю границу погрешности интерполяции:

$$\bar{\Delta}(P_n) = \frac{M_{n+1}}{(n+1)!} \max_{[a, b]} |\omega_{n+1}(x)|. \quad (11.34)$$

Поставим теперь задачу: определить набор узлов интерполяции  $x_0, x_1, \dots, x_n$ , при котором величина  $\bar{\Delta}(P_n)$  минимальна. Для решения этой задачи нам потребуются некоторые сведения о многочленах Чебышева<sup>2</sup>.

<sup>1</sup> Например, вычисление значений  $f(x)$  — трудоемкая операция.

<sup>2</sup> Пафнутий Львович Чебышев (1821—1894) — русский математик, один из создателей современных теории чисел, теории вероятностей, теории приближений функций.

**З а м е ч а н и е.** Формула (11.34) остается справедливой и в случае, когда некоторые из узлов  $x_0, x_1, \dots, x_n$  совпадают, т. е. имеет место интерполяция с кратными узлами.

**2. Многочлены Чебышева.** Введенные П.Л. Чебышевым многочлены  $T_n(x)$  широко используются в вычислительной математике. При  $n = 0$  и  $n = 1$  они определяются явными формулами

$$T_0(x) = 1, T_1(x) = x, \quad (11.35)$$

а при  $n \geq 2$  рекуррентной формулой

$$T_n(x) = 2xT_{n-1}(x) - T_{n-2}(x). \quad (11.36)$$

Запишем явные формулы для многочленов Чебышева  $T_n(x)$  при  $n = 2, 3, 4, 5$ :

$$\begin{aligned} T_2(x) &= 2xT_1(x) - T_0(x) = 2x^2 - 1, \\ T_3(x) &= 2xT_2(x) - T_1(x) = 4x^3 - 3x, \\ T_4(x) &= 2xT_3(x) - T_2(x) = 8x^4 - 8x^2 + 1, \\ T_5(x) &= 2xT_4(x) - T_3(x) = 16x^5 - 20x^3 + 5x. \end{aligned}$$

Аналогично можно записать явные формулы и при  $n \geq 6$ .

Приведем некоторые свойства многочленов Чебышева.

1<sup>0</sup>. При четном  $n$  многочлен  $T_n(x)$  содержит только четные степени  $x$  и является четной функцией, а при нечетном  $n$  многочлен  $T_n(x)$  содержит только нечетные степени  $x$  и является нечетной функцией.

2<sup>0</sup>. При  $n \geq 1$  старший коэффициент многочлена  $T_n(x)$  равен  $2^{n-1}$ , т. е.  $T_n(x) = 2^{n-1}x^n + \dots$ .

Справедливость свойств 1<sup>0</sup> и 2<sup>0</sup> следует непосредственно из определения (11.35), (11.36).

3<sup>0</sup>. Для  $x \in [-1, 1]$  справедлива формула

$$T_n(x) = \cos(n \arccos x). \quad (11.37)$$

□ При  $n = 0$  и  $n = 1$  формула (11.37) верна, так как  $\cos(0 \cdot \arccos x) = 1$ ,  $\cos(1 \cdot \arccos x) = x$ . Для того чтобы доказать справедливость формулы для всех  $n \geq 0$ , достаточно показать, что функции  $C_n(x) = \cos(n \arccos x)$  удовлетворяют такому же, как и многочлены Чебышева, рекуррентному соотношению

$$C_n(x) = 2x C_{n-1}(x) - C_{n-2}(x) \quad (11.38)$$

(ср. с (11.36)). Соотношение (11.38) получится, если в легко проверяемом тригонометрическом тождестве



$$\cos [(m+1)\varphi] + \cos [(m-1)\varphi] = 2\cos \varphi \cos m\varphi$$

положить  $m = n-1$  и  $\varphi = \arccos x$ . ■

4°. При  $n \geq 1$  многочлен  $T_n(x)$  имеет ровно  $n$  действительных корней, расположенных на отрезке  $[-1, 1]$  и вычисляемых по формуле

$$x_k = \cos \frac{(2k+1)\pi}{2n}, \quad k = 0, 1, \dots, n-1. \quad (11.39)$$

5°. При  $n \geq 0$  справедливо равенство  $\max_{[-1, 1]} |T_n(x)| = 1$ . Если  $n \geq 1$ ,

то этот максимум достигается ровно в  $n+1$  точках, которые находятся по формуле

$$x_m = \cos \left[ \frac{\pi m}{n} \right], \quad m = 0, 1, \dots, n. \quad (11.40)$$

При этом  $T_n(x_m) = (-1)^m$ , т. е. максимумы и минимумы многочлена Чебышева чередуются.

Доказательство свойств 4° и 5° основано на применении формулы (11.37). Например, в силу этой формулы корни многочлена  $T_n(x)$ , расположенные на отрезке  $[-1, 1]$ , совпадают с корнями уравнения  $\cos(n \arccos x) = 0$ . Эквивалентное преобразование этого уравнения дает  $n \arccos x = \pi/2 + \pi k$ ,  $k = 0, \pm 1, \pm 2, \dots$ . Так как  $0 \leq \arccos x \leq \pi$ , то заключаем, что имеется ровно  $n$  корней  $x_k$ , отвечающих значениям  $k = 0, 1, \dots, n-1$  и удовлетворяющих равенствам  $\arccos x_k = \frac{(2k+1)\pi}{2n}$ , эквивалентным формуле (11.39).

Назовем величину  $\max_{[-1, 1]} |P_n(x)|$  *уклонением* многочлена  $P_n(x)$  от нуля. Эта величина характеризует максимальное отклонение (уклонение) графика многочлена  $P_n$  от графика функции  $y = 0$  на отрезке  $[-1, 1]$ .

6°. Среди всех многочленов фиксированной степени  $n \geq 1$  со старшим коэффициентом  $a_n$ , равным 1, наименьшее отклонение от нуля (равное  $2^{1-n}$ ) имеет многочлен  $\bar{T}_n(x) = 2^{1-n} T_n(x)$ .

Благодаря этому свойству, имеющему особую ценность для приложений, многочлены Чебышева иногда называют *наименее уклоняющимися от нуля*. Свойство 6° иначе можно сформулировать так: для любого многочлена вида  $P_n(x) = x^n + a_{n-1}x^{n-1} + \dots + a_0$ , отличного от  $\bar{T}_n(x)$ , справедливо неравенство

$$2^{1-n} = \max_{[-1, 1]} |\bar{T}_n(x)| < \max_{[-1, 1]} |P_n(x)|.$$

Приведем графики многочленов  $T_n(x)$  для  $n = 1, 2, 3, 4, 5$  (рис. 11.3).

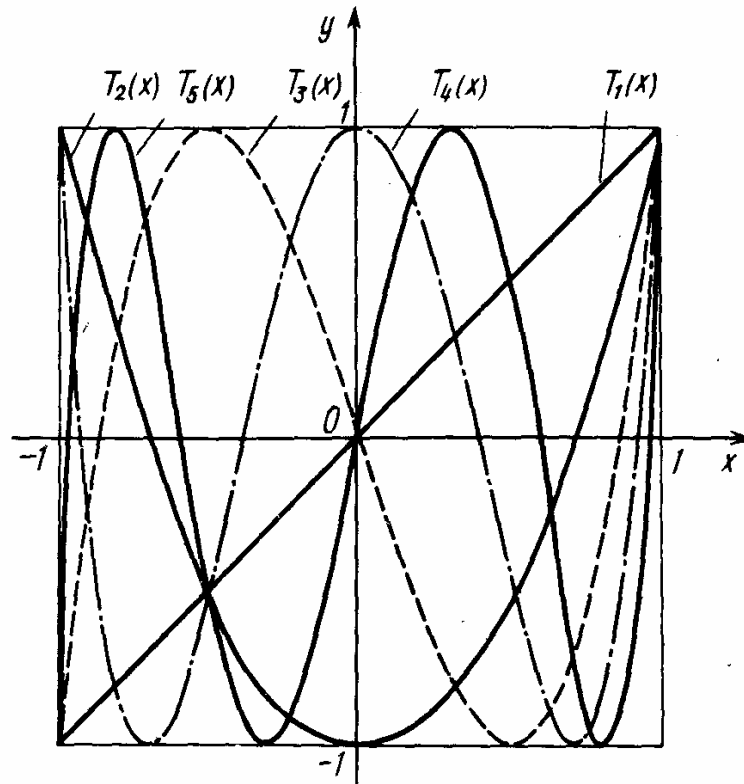


Рис. 11.3

**З а м е ч а н и е.** Из свойства 6<sup>0</sup> следует, что среди всех многочленов  $P_n(x)$  фиксированной степени  $n \geq 1$  со старшим коэффициентом  $a_n \neq 0$  наименьшее уклонение от нуля (равное  $|a_n| 2^{1-n}$ ) имеет многочлен  $a_n \bar{T}_n(x)$ .

Формулы (11.39) и (11.40) позволяют дать следующую геометрическую интерпретацию построения корней и точек экстремума многочлена  $T_n(x)$ . Разделим полуокружность, опирающуюся на отрезок  $[-1, 1]$  как на диаметр, на  $2n$  равных частей и спроецируем полученные точки на отрезок  $[-1, 1]$ . На рис. 11.4 изображен случай  $n = 5$ .

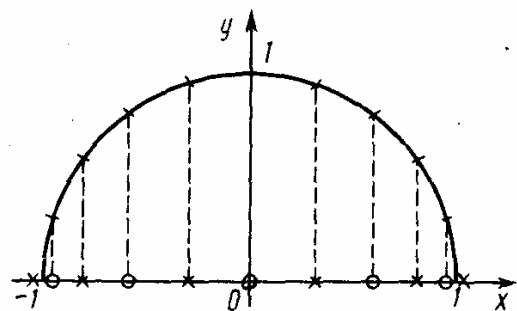


Рис. 11.4

Нумеруя проекции справа налево, получим, что все проекции с нечетными номерами являются корнями многочлена  $T_n$  (на рис. 11.4

они помечены кружочками), а все проекции с четными номерами — точками экстремума (они помечены крестиками). Заметим, что корни и точки экстремума сгущаются к концам отрезка  $[-1; 1]$ .

**3. Решение задачи минимизации оценки погрешности.** Найдем сначала решение задачи в предположении, что отрезок интерполяции  $[a, b]$  совпадает с отрезком  $[-1, 1]$ . В этом случае величина (11.34) будет минимальной при таком выборе узлов  $x_0, x_1, \dots, x_n$ , при котором минимальна величина  $\max_{[-1; 1]} |\omega_{n+1}(x)|$ , т. е. минимально уклонение многочлена  $\omega_{n+1}(x) = (x - x_0)(x - x_1)\dots(x - x_n)$  от нуля. В силу свойств 4<sup>о</sup> и 6<sup>о</sup> многочленов Чебышева решение задачи дает набор узлов

$$x_k = \cos \left[ \frac{2k + 1}{2n + 2} \pi \right], \quad k = 0, 1, \dots, n,$$

являющихся нулями многочлена  $T_{n+1}$ , так как в этом случае  $\omega_{n+1} = \bar{T}_{n+1}$ .

Заметим, что при таком выборе

$$\bar{\Delta}(P_n) = \frac{M_{n+1}}{(n + 1)! 2^n}, \quad (11.41)$$

причем в силу свойства 6<sup>о</sup> любой другой выбор узлов дает большее значение верхней границы погрешности. Для сравнения укажем, что при использовании для приближения функции  $f$  отрезка ряда Тейлора  $P_n(x) = \sum_{k=0}^n \frac{f^{(k)}(0)}{k!} x^k$  верхняя граница оценки погрешности такова:

$$\bar{\Delta}(P_n) = \frac{M_{n+1}}{(n + 1)!}.$$

Следовательно, она в  $2^n$  раз хуже, чем при интерполяции с оптимальным выбором узлов.

Пусть теперь отрезок интерполяции  $[a, b]$  произволен. Приведем его к стандартному отрезку  $[-1, 1]$  заменой

$$x = \frac{a + b}{2} + \frac{b - a}{2} t, \quad (11.42)$$

где  $t \in [-1, 1]$ . Как нетрудно видеть, в этом случае  $\omega_{n+1}(x) =$

$= \left[ \frac{b-a}{2} \right]^{n+1} \cdot \tilde{\omega}_{n+1}(t)$ , где  $\tilde{\omega}_{n+1}(t) = (t-t_0)(t-t_1)\dots(t-t_n)$  и  $x_k = \frac{a+b}{2} + \frac{b-a}{2} t_k$  для  $k = 0, 1, \dots, n$ . Следовательно,

$$\bar{\Delta}(P_n) = \frac{M_{n+1}}{(n+1)!} \left[ \frac{b-a}{2} \right]^{n+1} \max_{[-1, 1]} |\tilde{\omega}_{n+1}(t)|$$

и минимум этой величины достигается при значениях  $t_0, t_1, \dots, t_n$ , совпадающих с нулями многочлена  $T_{n+1}$ . Значит, решение поставленной задачи дает выбор узлов

$$x_k = \frac{a+b}{2} + \frac{b-a}{2} \cos \left[ \frac{2k+1}{2n+2} \pi \right], \quad k = 0, 1, \dots, n, \quad (11.43)$$

которому отвечает минимальное значение верхней границы погрешности интерполяции, равное

$$\bar{\Delta}(P_n) = \frac{M_{n+1}}{(n+1)!} \frac{1}{2^n} \left[ \frac{b-a}{2} \right]^{n+1}.$$

## § 11.7. Конечные разности

1. **Таблица конечных разностей.** Пусть функция  $y = f(x)$  задана таблицей (11.1) своих значений, причем  $x_0 < x_1 < \dots < x_n$  и расстояние  $h = x_i - x_{i-1}$  между соседними узлами таблицы значений аргумента постоянно. В этом случае величину  $h$  называют *шагом таблицы*, а узлы — *равноотстоящими*.

Величину  $\Delta y_i = y_{i+1} - y_i$  принято называть *конечной разностью первого порядка* функции  $y = f(x)$  в точке  $x_i$  (с шагом  $h$ ). *Конечная разность второго порядка* определяется формулой  $\Delta^2 y_i = \Delta y_{i+1} - \Delta y_i$ . Аналогично определяются конечные разности третьего и более высоких порядков. Общее определение *конечной разности порядка  $k$*  таково:

$$\Delta^k y_i = \Delta^{k-1} y_{i+1} - \Delta^{k-1} y_i.$$

Здесь  $k \geq 1$  и  $\Delta^0 y_i = y_i$ .

Таблицу конечных разностей (которые называют еще *конечными разностями вперед*) обычно располагают следующим образом:

Т а б л и ц а 11.2

$x$	$y$	$\Delta y$	$\Delta^2 y$	$\Delta^3 y$	...	$\Delta^n y$
$x_0$	$y_0$	$\Delta y_0$				
$x_1$	$y_1$	$\Delta y_1$	$\Delta^2 y_0$	$\Delta^3 y_0$		
$x_2$	$y_2$	$\Delta y_2$	$\Delta^2 y_1$	$\Delta^3 y_1$		
$x_3$	$y_3$		$\Delta^2 y_2$			$\Delta^n y_0$
.	.	.	.	.	.	.
.	.	.	.	.	.	.
.	.	$\Delta y_{n-2}$	.	$\Delta^3 y_{n-3}$	.	.
$x_{n-1}$	$y_{n-1}$	$\Delta y_{n-1}$	$\Delta^2 y_{n-2}$			
$x_n$	$y_n$					

2. Свойства конечных разностей. Можно показать, что конечные разности порядка  $k$  выражаются через значения функции в  $k + 1$  точке по формуле

$$\Delta^k y_i = \sum_{l=0}^k (-1)^{k-l} C_k^l y_{i+l}, \quad (11.44)$$

где  $C_k^l = \frac{k!}{l!(k-l)!}$  — биномиальные коэффициенты. В частности,

$$\begin{aligned} \Delta^2 y_i &= y_{i+2} - 2y_{i+1} + y_i, \\ \Delta^3 y_i &= y_{i+3} - 3y_{i+2} + 3y_{i+1} - y_i, \\ \Delta^4 y_i &= y_{i+4} - 4y_{i+3} + 6y_{i+2} - 4y_{i+1} + y_i. \end{aligned}$$

Приведем без доказательства важное утверждение, указывающее на тесную связь между производными гладких функций и их конечными разностями.

**Теорема 11.6.** Пусть функция  $f$  дифференцируема  $k$  раз на отрезке  $[x_i, x_{i+k}]$ . Тогда справедливо равенство

$$\Delta^k y_i = h^k f^{(k)}(\xi), \quad (11.45)$$

в котором  $\xi$  — некоторая точка из интервала  $(x_i, x_{i+k})$ .

**З а м е ч а н и е.** При  $k = 1$  формула (11.45) совпадает с формулой конечных приращений Лагранжа.

**С л е д с т в и е.** Для многочлена  $y = P_n(x) = \sum_{m=0}^n a_m x^m$  конечная разность порядка  $n$  является постоянной величиной, равной  $h^n n! a_n$ . Разности порядка  $k > n$  тождественно равны нулю.

Конечные разности имеют разнообразные практические применения. Например, если производная  $k$ -го порядка  $f^{(k)}$  слабо меняется на отрезке  $[x_i, x_{i+k}]$ , то в силу равенства (11.45) для  $x \in [x_i, x_{i+k}]$  справедлива следующая формула численного дифференцирования:

$$f^{(k)}(x) \approx \frac{\Delta^k y_i}{h^k}. \quad (11.46)$$

В § 11.9 конечные разности будут использованы для построения интерполяционного многочлена Ньютона. Рассмотрим еще два приложения конечных разностей, связанных с анализом погрешностей таблиц, а именно задачу об оценке уровня "шума" таблицы и задачу обнаружения единичных ошибок.

Заметим, что в реальных вычислениях таблица конечных разностей  $\Delta^k y_i$  строится по значениям  $y_j^*$ , каждое из которых содержит погрешность  $\varepsilon_j = y_j - y_j^*$ . Тогда в силу формулы (11.44) найденные значения  $\Delta^k y_j^*$  содержат неустраняемые ошибки

$$\varepsilon_i^{(k)} = \Delta^k y_i - \Delta^k y_i^* = \sum_{l=0}^k (-1)^{k-l} C_k^l \varepsilon_{i+l}. \quad (11.47)$$

Как нетрудно видеть, имеется тенденция к росту погрешностей  $\varepsilon_i^{(k)}$  с ростом  $k$ . Если известно, что  $|\varepsilon_i| \leq \varepsilon$  для всех  $i$ , то можно гарантировать справедливость лишь следующей оценки:

$$|\varepsilon_i^{(k)}| \leq \sum_{l=0}^k C_k^l \varepsilon = 2^k \varepsilon. \quad (11.48)$$

**3. Оценка уровня "шума" в таблице.** На практике часто возникает следующая задача. Для набора  $x_0, x_1, \dots, x_n$  равноотстоящих узлов каким-либо образом построена таблица приближенных значений гладкой функции  $y = f(x)$ . Требуется оценить уровень погрешности (уровень "шума") таблицы.

Полученная выше гарантированная оценка погрешности (11.48) не дает удовлетворительного ответа на поставленный вопрос. Она лишь

указывает на то, что в самом неблагоприятном случае рост ошибки произойдет с коэффициентом, равным  $2^k$ . Проведем статистический анализ погрешности. Будем предполагать, что ошибки  $\varepsilon_j$  ( $j = 0, 1, \dots, n$ ) являются независимыми случайными величинами с математическим ожиданием  $M[\varepsilon_j] = 0$  (это эквивалентно отсутствию систематической составляющей погрешности) и дисперсией  $M[\varepsilon_j^2] = \sigma^2$ .

В силу формулы (11.47)  $M[\varepsilon_i^{(k)}] = 0$  и тогда для дисперсии  $(\sigma^{(k)})^2 = M[(\varepsilon_i^{(k)})^2]$  погрешности  $k$ -й разности имеем:

$$\begin{aligned} (\sigma^{(k)})^2 &= M\left[\left(\sum_{l=0}^k (-1)^{k-l} C_k^l \varepsilon_{i+l}\right)\left(\sum_{r=0}^k (-1)^{k-r} C_k^r \varepsilon_{i+r}\right)\right] = \\ &= M\left[\sum_{l=0}^k (C_k^l)^2 \varepsilon_{i+l}^2 + \sum_{l \neq r} (-1)^{l+r} C_k^l C_k^r \varepsilon_{i+l} \varepsilon_{i+r}\right]. \end{aligned}$$

Заметим, что  $\sum_{l=0}^k (C_k^l)^2 = C_{2k}^k$  и  $M[\varepsilon_{i+l} \varepsilon_{i+r}] = 0$  при  $l \neq r$ , так как величины  $\varepsilon_{i+l}$  и  $\varepsilon_{i+r}$  независимы. Следовательно,  $(\sigma^{(k)})^2 = C_{2k}^k \sigma^2$ .

Принимая за уровень "шума" таблицы величину  $\sigma$  квадратного корня из дисперсии (среднеквадратичную ошибку), получим равенство

$$\sigma^{(k)} = \sqrt{C_{2k}^k} \sigma, \quad (11.49)$$

которое дает более оптимистичное по сравнению с оценкой (11.47)

значение коэффициента роста ошибки, так как  $\sqrt{C_{2k}^k} < 2^k$ .

Если конечные разности  $\Delta^k y_i^*$  строятся для гладкой функции, то они часто имеют тенденцию с ростом  $k$  уменьшаться по абсолютной величине, а затем, начиная с некоторого  $k = p$ , возрастать, испытывая сильные колебания в пределах одного столбца. При этом для  $k \geq p$  основной вклад в значение  $\Delta^k y_i^*$  вносит величина  $\varepsilon_i^{(k)}$ . Это обстоятельство позволяет считать, что в оценке дисперсии  $(\sigma^{(p)})^2 \approx \frac{1}{n-p+1} \sum_{i=0}^{n-p} (\varepsilon_i^{(p)})^2$  величины  $\varepsilon_i^{(p)}$  можно приближенно заменить на  $\Delta^p y_i^*$ . Вычислив  $\sigma^{(p)}$ , затем достаточно воспользоваться формулой (11.49) для оценки уровня "шума" таблицы.

**Пример 11.5.** Оценим уровень "шума" в таблице значений функции  $y = \ln x$ , заданной с шагом  $h = 0.1$  (первый и второй столбцы табл. 11.3). Сос-

тавив таблицу конечных разностей<sup>1</sup>, замечаем, что, начиная с  $k = 5$ , абсолютные значения разностей  $\Delta^k y_j$  начинают возрастать. Оценим  $\sigma^{(5)}$  следующим образом:

$$\sigma^{(5)} \approx \left[ \frac{1}{6} \sum_{i=0}^5 (\Delta^5 y_i)^2 \right]^{1/2} \approx 3.5 \cdot 10^{-4}.$$

Учитывая, что  $C_{10}^5 = 252$ , имеем  $\sigma = \sigma^{(5)} / \sqrt{252} \approx 2 \cdot 10^{-5}$ . Таким образом, погрешность таблицы составляет примерно две единицы 5-го разряда, а 6-й и 7-й разряды уже не содержат полезной информации. Если бы таблицу предполагалось использовать на практике, то, по-видимому, имело бы смысл округлить значения  $y_i$  до 5 значащих цифр после десятичной точки.

Т а б л и ц а 11.3

$x$	$y$	$\Delta y$	$\Delta^2 y$	$\Delta^3 y$	$\Delta^4 y$	$\Delta^5 y$
1.0	0.0000000	953274				
1.1	0.0953274	869958	-83316	13874		
1.2	0.1823232	800516	-69442	9812	-4062	3216
1.3	0.2623748	740886	-59630	8966	-846	-2525
1.4	0.3364634	690222	-50664	5595	-3371	4161
1.5	0.4054856	645153	-45069	6385	790	-3636
1.6	0.4700009	606469	-38684	3539	-2846	3992
1.7	0.5306478	571324	-35145	4685	1146	-3473
1.8	0.5877802	540864	-30460	2358	-2327	
1.9	0.6418666	512752	-28102			
2.0	0.6931428					

<sup>1</sup> Следуя общепринятым обозначениям, мы записываем конечные разности так, как если бы десятичная точка следовала за последними разрядами, отведенными для значения функции.



4. **Обнаружение единичных ошибок.** Анализ таблиц конечных разностей позволяет в некоторых случаях обнаруживать грубые единичные ошибки в таблицах гладких функций и даже частично их устранять. Прежде чем продемонстрировать сказанное на примере, рассмотрим, как распространяется в таблице конечных разностей ошибка  $\epsilon$ , допущенная только в одном значении  $y_i$ . Пользуясь формулой (11.47) или равенством  $\epsilon_j^{(k)} = \epsilon_{j+1}^{(k-1)} - \epsilon_j^{(k-1)}$  (где  $\epsilon_j^{(0)} = \epsilon$  при  $j = i$  и  $\epsilon_j^{(0)} = 0$  при  $j \neq i$ ), получим следующую таблицу распространения единичной ошибки, т. е. ошибки, допущенной в одной точке.

Т а б л и ц а 11.4

$x$	$\epsilon^{(0)}$	$\epsilon^{(1)}$	$\epsilon^{(2)}$	$\epsilon^{(3)}$	$\epsilon^{(4)}$	.....	$\epsilon^{(k)}$
.....							$\epsilon$
.....							
$x_{i-2}$	0		0		$\epsilon$		$-C_k^{k-1} \epsilon$
		0		$\epsilon$			
$x_{i-1}$	0		$\epsilon$		$-4\epsilon$		$C_k^{k-2} \epsilon$
		$\epsilon$		$-3\epsilon$			
$x_i$	$\epsilon$		$-2\epsilon$		$6\epsilon$		
		$-\epsilon$		$3\epsilon$			
$x_{i+1}$	0		$\epsilon$		$-4\epsilon$		$(-1)^{k-2} C_k^2 \epsilon$
		0		$-\epsilon$			
$x_{i+2}$	0		0		$\epsilon$		$(-1)^{k-1} C_k^1 \epsilon$
.....							
.....							$(-1)^k \epsilon$

**Пример 11.6.** Пусть на отрезке  $[1.5, 2.8]$  задана таблица значений функции  $y = \ln x$  (первый и второй столбцы табл. 11.5). Составим для нее таблицу конечных разностей. Аномальное поведение разностей третьего и четвертого порядка указывает на наличие в таблице значений функции ошибки. Сравнение с табл. 11.4 распространения единичной ошибки приводит к заключению о том, что погрешность допущена в значении  $y$ , отвечающем  $x = 2.2$ . Тогда погрешностям  $\epsilon, -4\epsilon, 6\epsilon, -4\epsilon, \epsilon$  табл. 11.4 приближенно отвечают значения

$262 \cdot 10^{-6}$ ,  $-1231 \cdot 10^{-6}$ ,  $1774 \cdot 10^{-6}$ ,  $-1222 \cdot 10^{-6}$ ,  $282 \cdot 10^{-6}$  табл. 11.5. Это соответствие имеет место при  $\epsilon \approx 298 \cdot 10^{-6}$ . Следовательно, табличное значение 0.788757 нужно заменить на 0.788459.

Т а б л и ц а 11.5

$x$	$y$	$\Delta y$	$\Delta^2 y$	$\Delta^3 y$	$\Delta^4 y$
1.5	0.405465	64539			
1.6	0.470004	60624	-3915	450	
1.7	0.530628	57159	-3465	373	-77
1.8	0.587787	54067	-3092	318	-55
1.9	0.641854	51293	-2774	271	-47
2.0	0.693147	48790	-2503	533	262
2.1	0.741937	46820	-1970	-698	-1231
2.2	0.788757	44152	-2668	1076	1774
2.3	0.832909	42560	-1592	-146	-1222
2.4	0.875469	40822	-1738	136	282
2.5	0.916291	39220	-1602	123	-13
2.6	0.955511	37741	-1479	105	-18
2.7	0.993252	36367	-1374		
2.8	1.029619				

**З а м е ч а н и е.** Часто вместо конечных разностей вперед  $\Delta^k y_i$  используют *разности назад*, определяемые рекуррентной формулой

$$\nabla^k y_i = \nabla^{k-1} y_i - \nabla^{k-1} y_{i-1}.$$

Здесь  $k \geq 1$ ,  $\nabla^0 y_i = y_i$ . Заметим, что разности вперед и назад связаны равенством

$$\Delta^k y_i = \nabla^k y_{i+k}.$$

## § 11.8. Разделенные разности

1. **Таблица разделенных разностей.** Пусть функция  $f$  задана на таблице  $x_0, x_1, \dots, x_n$  значений аргумента с произвольным (не обязательно постоянным) шагом, причем точки таблицы занумерованы в произвольном (не обязательно возрастающем) порядке. Величины

$$f(x_i; x_{i+1}) = \frac{f(x_{i+1}) - f(x_i)}{x_{i+1} - x_i}$$

принято называть *разделенными разностями первого порядка* функции  $f$ . *Разделенные разности второго порядка* определяются формулой

$$f(x_i; x_{i+1}; x_{i+2}) = \frac{f(x_{i+1}; x_{i+2}) - f(x_i; x_{i+1})}{x_{i+2} - x_i}.$$

Аналогично определяются разделенные разности третьего и более высоких порядков. Общее определение *разделенной разности порядка*  $k \geq 2$  таково:

$$f(x_i; x_{i+1}, \dots, x_{i+k}) = \frac{f(x_{i+1}; \dots; x_{i+k}) - f(x_i; \dots; x_{i+k-1})}{x_{i+k} - x_i}.$$

Таблицу разделенных разностей обычно располагают следующим образом:

Т а б л и ц а 11.6

---

$x_0$	$f(x_0)$			
		$f(x_0; x_1)$		
$x_1$	$f(x_1)$		$f(x_0; x_1; x_2)$	
		$f(x_1; x_2)$		
$x_2$	$f(x_2)$			$f(x_0; x_1; \dots; x_n)$
			$f(x_{n-2}; x_{n-1}; x_n)$	
		$f(x_{n-1}; x_n)$		
$x_n$	$f(x_n)$			

2. **Свойства разделенных разностей.** Разделенные разности обладают рядом замечательных свойств. Перечислим без доказательства некоторые из них.

1<sup>0</sup>. Разделенная разность  $f(x_i; x_{i+1}; \dots; x_{i+k})$  является симметричной функцией своих аргументов  $x_i, x_{i+1}, \dots, x_{i+k}$  (т. е. ее значение не меняется при любой их перестановке).

2<sup>0</sup>. Пусть функция  $f$  имеет на отрезке  $[a, b]$ , содержащем точки  $x_i, x_{i+1}, \dots, x_{i+k}$ , производную порядка  $k$ . Тогда справедливо равенство

$$f(x_i; x_{i+1}; \dots; x_{i+k}) = \frac{f^{(k)}(\xi)}{k!}, \quad (11.50)$$

где  $\xi$  — некоторая точка, расположенная на интервале  $(a, b)$ .

3<sup>0</sup>. В случае, когда таблица значений аргумента имеет постоянный шаг  $h$ , разделенная и конечная разности связаны равенством

$$f(x_i; x_{i+1}; \dots; x_{i+k}) = \frac{\Delta^k y_i}{h^k k!}. \quad (11.51)$$

**Пример 11.7.** Приведем таблицу (табл. 11.7) разделенных разностей для функции, заданной табл. 11.1. Вычисления произведены на 6-разрядной десятичной ЭВМ.

Т а б л и ц а 11.7

1.0	0.000000				
		0.953100			
1.1	0.095310		-0.414900		
		0.870120		0.221333	
1.2	0.182322		<u>-0.348500</u>		<u>-0.121665</u>
		<u>0.800420</u>		<u>0.172667</u>	
1.3	0.262364		-0.296700		
		0.741080			
1.4	0.336472				

Перенумеруем теперь узлы, положив  $x_0 = 1.2$ ,  $x_1 = 1.3$ ,  $x_2 = 1.1$ ,  $x_3 = 1.4$ ,  $x_4 = 1.0$ . Тогда таблица разделенных разностей примет следующий вид:

Т а б л и ц а 11.8

1.2	0.182322				
		<u>0.800420</u>			
1.3	0.262364		<u>-0.348500</u>		
		0.835270		<u>0.172650</u>	
1.1	0.095310		-0.313970		<u>-0.121750</u>
		0.803873		0.197000	
1.4	0.336472		-0.373070		
		0.841180			
1.0	0.000000				

В табл. 11.8 подчеркнуты разделенные разности, которые совпадают (как и должно быть в силу свойства 1<sup>0</sup>) с точностью до вычислительной погрешности с соответствующими разделенными разностями из табл. 11.7 (они также подчеркнуты).

## § 11.9. Интерполяционный многочлен Ньютона.

### Схема Эйткена

**1. Интерполяционный многочлен Ньютона с разделенными разностями.** Используя разделенные разности, интерполяционный многочлен можно записать в следующем виде:

$$P_n(x) = f(x_0) + f(x_0; x_1)(x - x_0) + f(x_0; x_1; x_2)(x - x_0)(x - x_1) + \dots \\ \dots + f(x_0; x_1; \dots, x_n)(x - x_0)(x - x_1) \dots (x - x_{n-1}) = \sum_{k=0}^n f(x_0; x_1; \dots, x_k) \omega_k(x). \quad (11.52)$$

Здесь  $\omega_0(x) \equiv 1$ ,  $\omega_k(x) = (x - x_0)(x - x_1) \dots (x - x_{k-1})$ . Записанный в таком виде интерполяционный многочлен называют *интерполяционным многочленом Ньютона с разделенными разностями*.

**З а м е ч а н и е 1.** Отметим очевидную (с учетом равенства (11.50)) аналогию между формулой Ньютона (11.52) и формулой Тейлора (11.32).

**З а м е ч а н и е 2.** Формулу (11.25) для погрешности интерполяции в точке  $x$ , не являющейся узловой, можно уточнить следующим образом:

$$f(x) - P_n(x) = f(x_0; \dots; x_n; x) \omega_{n+1}(x). \quad (11.53)$$

Мы не приводим доказательства этой замечательной формулы. Отметим лишь, что если воспользоваться свойством 2<sup>0</sup> разделенных разностей, то из нее немедленно получается формула (11.25).

В практическом плане формула (11.52) обладает рядом преимуществ перед формулой Лагранжа. Пусть, например, по каким-либо причинам необходимо увеличить степень интерполяционного многочлена на единицу, добавив в таблицу еще один узел  $x_{n+1}$ . При использовании формулы Лагранжа (11.22) это приводит не только к увеличению числа слагаемых, но и к необходимости вычислять каждое из них заново. В то же время для вычисления  $P_{n+1}(x)$  по формуле Ньютона

(11.52) достаточно добавить к  $P_n(x)$  лишь одно очередное слагаемое, так как

$$P_{n+1}(x) - P_n(x) = f(x_0; \dots; x_n; x_{n+1}) \omega_{n+1}(x). \quad (11.54)$$

Заметим, что в случае, когда величина  $|x_{n+1} - x|$  мала, а функция  $f$  достаточно гладкая, справедливо приближенное равенство

$$f(x_0; \dots; x_n; x) \approx f(x_0; \dots; x_n; x_{n+1}),$$

из которого с учетом равенств (11.53) и (11.54) следует, что

$$f(x) - P_n(x) \approx P_{n+1}(x) - P_n(x).$$

Таким образом, величину

$$\varepsilon_n = |P_{n+1}(x) - P_n(x)| \quad (11.55)$$

можно использовать для практической оценки погрешности интерполяции.

**Пример 11.8.** По табл. 11.1 значений функции  $y = \ln x$  из примера 11.3 найдем приближенное значение  $\ln x$  при  $x = 1.23$ , используя интерполяционные многочлены Ньютона с разделенными разностями  $P_k(x)$  для  $k = 0, 1, \dots, 4$ . Оценим при  $k = 0, 1, 2, 3$  погрешность интерполяции по формуле (11.55).

Занумеруем узлы таблицы в следующем порядке:  $x_0 = 1.2$ ,  $x_1 = 1.3$ ,  $x_2 = 1.1$ ,  $x_3 = 1.4$ ,  $x_4 = 1.0$ , т. е. в порядке возрастания расстояния до точки  $x = 1.23$ . Соответствующие этой нумерации разделенные разности приведены в табл. 11.8 (мы используем только подчеркнутые разности).

Вычисления на 6-разрядной десятичной ЭВМ дают следующие значения:

$$\begin{aligned} P_0(x) &= 0.182322, \quad P_1(x) = P_0(x) + f(x_0; x_1) \omega_1(x) \approx 0.182322 + \\ &+ 0.80042 \cdot (1.23 - 1.2) \approx 0.206335, \quad \varepsilon_0 = |P_1(x) - P_0(x)| \approx 2.4 \cdot 10^{-2}, \\ P_2(x) &= P_1(x) + f(x_0; x_1; x_2) \omega_2(x) \approx 0.206335 - 0.3485(1.23 - 1.2)(1.23 - \\ &- 1.3) \approx 0.207067, \quad \varepsilon_1 = |P_2(x) - P_1(x)| \approx 7.3 \cdot 10^{-4}. \end{aligned}$$

Аналогично получаются значения  $P_3(x) \approx 0.207020$ ,  $\varepsilon_2 \approx 4.7 \cdot 10^{-5}$ ,  $P_4(x) \approx 0.207014$ ,  $\varepsilon_3 \approx 6 \cdot 10^{-6}$ .

Если бы задача состояла в определении значения  $\ln(1.23)$  с точностью  $\varepsilon = 10^{-4}$ , то вычисления следовало бы окончить после получения  $\varepsilon_2 < \varepsilon$ . Результат был бы таким:  $\ln(1.23) \approx P_2(x) \approx 0.2071$ .

2. Интерполяция с использованием схемы Эйткена. Рассмотрим один из алгоритмов решения задачи интерполяции. Предполагается, что задана таблица значений функции  $f$ . Требуется при заданном  $x$  вычислить с помощью интерполяции значение  $f(x)$  с заданной точностью  $\varepsilon$  либо с максимально возможной при имеющейся информации точностью. Считается, что функция  $f$  достаточно гладкая.

Обозначим через  $P_{(k,k+1, \dots, m)}(x)$  интерполяционный многочлен степени  $m - k$  с узлами интерполяции  $x_k, x_{k+1}, \dots, x_m$ . В частности, положим  $P_{(k)}(x) = y_k$ . В этих обозначениях справедливо равенство

$$P_{(k,k+1, \dots, m+1)}(x) = \frac{P_{(k+1, \dots, m+1)}(x)(x-x_k) - P_{(k, \dots, m)}(x)(x-x_{m+1})}{x_{m+1} - x_k}. \quad (11.56)$$

В самом деле, правая часть представляет собой многочлен степени  $m + 1 - k$ . Непосредственная проверка показывает, что этот многочлен совпадает с  $y_i$  в точках  $x = x_i$  для  $i = k, k + 1, \dots, m + 1$  и, значит, по определению равен  $P_{(k, \dots, m+1)}(x)$ .

Удобный и экономичный способ вычисления значения многочлена  $P_n(x) = P_{(0,1, \dots, n)}(x)$ , лежащий в основе рассматриваемого алгоритма, дает *схема Эйткена*<sup>1</sup>. Она заключается в последовательном вычислении с помощью формулы (11.56) элементов следующей таблицы:

Т а б л и ц а 11.9

---

$P_{(0)}(x) = y_0$			
	$P_{(0,1)}(x)$		
$P_{(1)}(x) = y_1$		$P_{(0,1,2)}(x)$	
	$P_{(1,2)}(x)$		
$P_{(2)}(x) = y_2$			$P_{(0,1, \dots, n)}(x)$
		$P_{(n-2, n-1, n)}(x)$	
	$P_{(n-1, n)}(x)$		
$P_{(n)}(x) = y_n$			

Для решения поставленной задачи интерполяции при заданном значении  $x$  узлы нумеруют в порядке возрастания их расстояния  $|x - x_k|$  до точки  $x$ . Затем последовательно вычисляют значения  $P_1(x)$ ,  $\varepsilon_0$ ,  $P_2(x)$ ,  $\varepsilon_1$ , ...,  $P_{m+1}(x)$ ,  $\varepsilon_m$ , ... . Если при некотором  $m$  оказывается,

---

<sup>1</sup> Александр Крэг Эйткен (1895—1967) — английский математик.

что  $\varepsilon_m \leq \varepsilon$ , то полагают  $f(x) \approx P_m(x)$ . Если же  $\varepsilon_m > \varepsilon$  для всех  $m$ , то полагают  $f(x) \approx P_k(x)$ , где  $k$  — степень, при которой достигается минимум оценки погрешности:  $\varepsilon_k = \min_{m \geq 0} \varepsilon_m$ .

**Пример 11.9.** Для решения задачи из примера 11.8 воспользуемся схемой Эйткена. В этом случае (как и в примере 11.8)  $x_0 = 1.2$ ,  $x_1 = 1.3$ ,  $x_2 = 1.1$ ,  $x_3 = 1.4$ ,  $x_4 = 1.0$ . После завершения вычислений табл. 11.9 принимает следующий вид:

Т а б л и ц а 11.10

<u>0.182322</u>			
	<u>0.206335</u>		
0.262364		<u>0.207067</u>	
	0.203895		<u>0.207020</u>
0.095310		0.206752	
	0.199814		
0.336472			

Подчеркнутые числа дают те же, что и в примере 11.8, значения  $P_k(x)$ ,  $k = 0, 1, 2, 3$ . Естественно, что теми же окажутся и значения  $\varepsilon_k$ .

**3. Интерполяционный многочлен Ньютона с конечными разностями.** Пусть интерполируемая функция задана на таблице с постоянным шагом  $h$  (т. е.  $x_i = x_0 + ih$ ,  $i = 0, 1, \dots, n$ ). В этом случае, используя формулу (11.51) связи между разделенными и конечными разностями и вводя безразмерную переменную  $t = (x - x_0)/h$ , многочлен Ньютона (11.52) можно записать в следующем виде:

$$P_n(x) = P_n(x_0 + ht) = y_0 + \frac{\Delta y_0}{1!} t + \frac{\Delta^2 y_0}{2!} t(t-1) + \frac{\Delta^3 y_0}{3!} t(t-1)(t-2) + \dots + \frac{\Delta^n y_0}{n!} t(t-1)\dots(t-n+1). \quad (11.57)$$

Многочлен (11.57) называется *интерполяционным многочленом Ньютона с конечными разностями для интерполяции вперед*.

Заметим, что в формуле (11.57) используются только конечные разности, расположенные в верхней кривой строке табл. 11.2. Можно использовать конечные разности, расположенные и в нижней кривой строке табл. 11.2, записав многочлен в виде *интерполяционного многочлена Ньютона с конечными разностями для интерполяции назад*:



$$P_n(x) = P_n(x_n + hq) = y_n + \frac{\Delta y_{n-1}}{1!} q + \frac{\Delta^2 y_{n-2}}{2!} q(q+1) + \frac{\Delta^3 y_{n-3}}{3!} q(q+1)(q+2) + \dots + \frac{\Delta^n y_0}{n!} q(q+1)\dots(q+n-1). \quad (11.58)$$

Здесь  $q = (x - x_n)/h$ .

### § 11.10. Обсуждение глобальной полиномиальной интерполяции.

#### Понятие о кусочно-полиномиальной интерполяции

Пусть функция интерполируется на отрезке  $[a, b]$ . Метод решения этой задачи с помощью интерполяции единым для всего отрезка многочленом  $P_n(x)$  называют *глобальной полиномиальной интерполяцией*. При первом знакомстве с интерполяцией этот подход кажется привлекательным. В самом деле, неплохо иметь один многочлен, пригодный для приближения функции  $f$  во всех точках  $x \in [a, b]$ . В то же время известные результаты теории аппроксимации позволяют надеяться на то, что удастся приблизить функцию с любой требуемой точностью  $\varepsilon$  с помощью соответствующего выбора степени многочлена и узлов интерполяции на отрезке  $[a, b]$ . Приведем один такой классический результат.

**Т е о р е м а 11.6** (аппроксимационная теорема Вейерштрасса<sup>1</sup>). Пусть функция  $f$  непрерывна на отрезке  $[a, b]$ . Тогда для любого  $\varepsilon > 0$  существует полином  $P_n(x)$  степени  $n = n(\varepsilon)$  такой, что

$$\max_{[a, b]} |f(x) - P_n(x)| < \varepsilon.$$

Заметим, что теорема Вейерштрасса не дает конструктивного способа построения соответствующего многочлена.

Несмотря на приведенные выше аргументы, существуют весьма веские причины, по которым глобальная интерполяция многочленами высокой степени в вычислительной практике, как правило, не используется. Обсудим некоторые из этих причин.

---

<sup>1</sup> Карл Теодор Вильгельм Вейерштрасс (1815—1897) — немецкий математик, один из основоположников современного математического анализа и теории аналитических функций.

1. **Сходимость при увеличении числа узлов.** Всегда ли можно добиться повышения точности интерполяции благодаря увеличению числа узлов (и соответственно степени  $n$  интерполяционного многочлена)? Хотя положительный ответ на этот вопрос напрашивается сам собой, не будем торопиться с выводами.

Уточним постановку задачи. Для того чтобы реализовать процесс интерполяции функции  $f$  многочленами возрастающей степени  $n$ , необходимо указать стратегию выбора при каждом  $n$  набора узлов интерполяции  $x_0^{(n)}, x_1^{(n)}, \dots, x_n^{(n)}$ . Такая стратегия задается указанием *интерполяционного массива* — треугольной таблицы

$$\begin{array}{ccccccc} x_0^{(0)} & & & & & & \\ x_0^{(1)} & x_1^{(1)} & & & & & \\ x_0^{(2)} & x_1^{(2)} & x_2^{(2)} & & & & \\ \dots & \dots & \dots & \dots & \dots & \dots & \\ x_0^{(n)} & x_1^{(n)} & x_2^{(n)} & \dots & x_n^{(n)} & & \end{array},$$

в каждой строке которой все  $x_i^{(n)}$  различны и  $x_i^{(n)} \in [a, b]$ . Будем говорить, что при заданной стратегии выбора узлов *метод интерполяции сходится*, если  $\max_{[a, b]} |f(x) - P_n(x)| \rightarrow 0$  при  $n \rightarrow \infty$ .

Рассмотрим сначала простейшую стратегию, состоящую в равномерном распределении на отрезке  $[a, b]$  узлов интерполяции, т. е. в выборе  $x_i^{(n)} = a + ih$  ( $i = 0, 1, \dots, n$ ), где  $h = (b - a)/n$ . Следующий пример показывает, что такая стратегия не может обеспечить сходимость интерполяции даже для очень гладких функций.

**Пример 11.10** (пример Рунге<sup>1</sup>). Используем глобальную полиномиальную интерполяцию с равномерным распределением узлов для приближения на отрезке  $[-1, 1]$  следующей функции:

$$f(x) = \frac{1}{1 + 25x^2}. \quad (11.59)$$

Вычисления показывают, что при больших  $n$  интерполяция дает превосходные результаты в центральной части отрезка. В то же время вопреки ожиданиям последовательность  $P_n(x)$  расходится при  $n \rightarrow \infty$  для  $0.73 \lesssim |x| \leq 1$ . Соответствующая иллюстрация приведена на рис. 11.5.

<sup>1</sup> Карл Давид Тольме Рунге (1856—1927) — немецкий физик и математик.

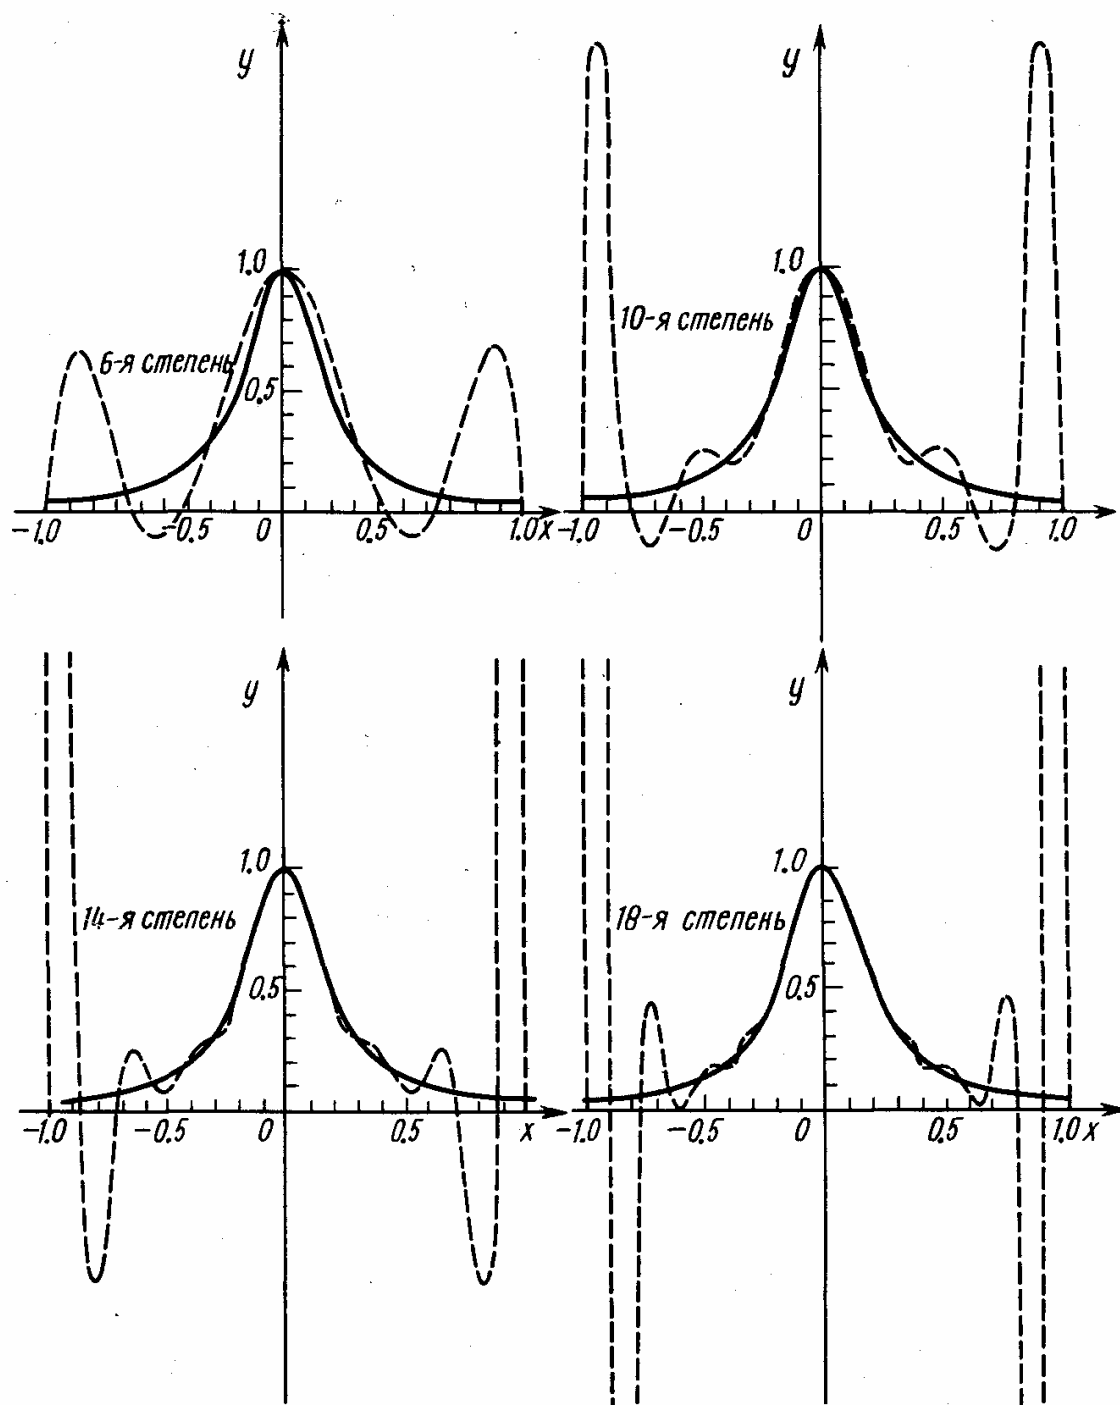


Рис. 11.5

Равномерное распределение узлов интерполяции для функции Рунге (11.59) оказалось неудачным. Однако проблема сходимости для этой функции исчезает, если в качестве узлов интерполяции брать корни многочлена Чебышева  $T_{n+1}(x)$ . Существует ли единая для всех непрерывных на отрезке  $[a, b]$  функций  $f$  стратегия выбора узлов ин-

терполяции, гарантирующая ее сходимость? Отрицательный ответ на этот вопрос дает следующая теорема.

**Т е о р е м а 11.7 (теорема Фабера<sup>1</sup>).** *Какова бы ни была стратегия выбора узлов интерполяции, найдется непрерывная на отрезке  $[a, b]$  функция  $f$ , для которой  $\max |f(x) - P_n(x)| \rightarrow \infty$  при  $n \rightarrow \infty$ .*

Теорема Фабера отрицает существование единой для всех непрерывных функций стратегии выбора узлов интерполяции. Однако для гладких функций (а именно такие функции чаще всего и интерполируются) такая стратегия существует, о чем говорит следующая теорема.

**Т е о р е м а 11.8.** *Пусть в качестве узлов интерполяции на отрезке  $[a, b]$  выбираются чебышевские узлы (11.43). Тогда для любой непрерывно дифференцируемой на отрезке  $[a, b]$  функции  $f$  метод интерполяции сходится.*

**З а м е ч а н и е.** Практическая реализация стратегии выбора узлов интерполяции (11.43) возможна и оправдана в довольно редких случаях и просто невозможна тогда, когда приходится иметь дело с заданной таблицей значений функции.

**2. Чувствительность интерполяционного многочлена к погрешностям входных данных.** Помимо погрешности, которая возникает от приближенной замены функции  $f$  интерполяционным многочленом, возникает еще дополнительная погрешность, связанная с тем, что значения интерполируемой функции также задаются с погрешностью.

Пусть заданные в узлах  $x_i$  значения  $y_i^*$  содержат погрешности  $\varepsilon_i$ .

Тогда вычисляемый по этим значениям многочлен  $P_n^*(x) = \sum_{j=0}^n y_j^* l_{nj}(x)$  содержит погрешность

$$P_n(x) - P_n^*(x) = \sum_{j=0}^n \varepsilon_j l_{nj}(x). \quad (11.60)$$

Например, при линейной интерполяции по приближенно заданным значениям справедливо равенство

$$P_1(x) - P_1^*(x) = \varepsilon_0 h_{10}(x) + \varepsilon_1 h_{11}(x),$$

где

---

<sup>1</sup> Жорж Фабер (1877—1966) — швейцарский математик.

$$l_{10}(x) = \frac{x - x_1}{x_0 - x_1}, \quad l_{11}(x) = \frac{x - x_0}{x_1 - x_0}.$$

Воспользуемся тем, что  $|l_{10}(x)| + |l_{11}(x)| = 1$  для  $x \in [x_0, x_1]$ . Следовательно,

$$\max_{[x_0, x_1]} |P_1(x) - P_1^*(x)| \leq \max \{|\varepsilon_0|, |\varepsilon_1|\}.$$

Таким образом, при линейной интерполяции погрешность, возникающая вследствие погрешности значений функции, не превосходит верхней границы погрешности этих значений.

Рассмотрим теперь общий случай. Пусть известно, что верхняя граница погрешности значений  $y_i^*$  равна  $\bar{\Delta}(y^*)$ , т. е.  $|\varepsilon_i| \leq \bar{\Delta}(y^*)$  для всех  $i = 0, 1, \dots, n$ . Тогда для верхней границы соответствующей погрешности многочлена  $\bar{\Delta}(P_n^*) = \max_{[a, b]} |P_n(x) - P_n^*(x)|$  в силу равенства

(11.60) справедлива оценка

$$\bar{\Delta}(P_n^*) \leq \Lambda_n \bar{\Delta}(y^*). \quad (11.61)$$

Здесь  $\Lambda_n = \max_{[a, b]} \sum_{j=0}^n |l_{nj}(x)|$  — величина, которую называют *константой Лебега*<sup>1</sup>.

**З а м е ч а н и е.** В случае, когда  $|\varepsilon_i| = \bar{\Delta}(y^*)$  для всех  $i$ , выбором знаков погрешностей  $\varepsilon_i$  можно добиться выполнения равенства  $\bar{\Delta}(P_n^*) = \Lambda_n \bar{\Delta}(y^*)$ . Это означает, что в самом неблагоприятном случае погрешность входных данных при интерполяции может возрасти в  $\Lambda_n$  раз. Таким образом, в задаче интерполирования константа Лебега играет роль абсолютного числа обусловленности.

Величина  $\Lambda_n$  не зависит от длины отрезка  $[a, b]$ , а определяется лишь относительным расположением узлов на нем. Для того чтобы

---

<sup>1</sup> Анри Леон Лебег (1875—1941) — французский математик, один из создателей современной теории функций вещественной переменной и теории интегрирования.

показать это, приведем отрезок  $[a, b]$  к стандартному отрезку  $[-1, 1]$  с помощью линейного преобразования  $x = \frac{a+b}{2} + \frac{b-a}{2}t$ . Тогда  $x_i = \frac{a+b}{2} + \frac{b-a}{2}t_i$  и константа Лебега приводится к виду

$$\Lambda_n = \max_{[-1, 1]} \sum_{j=0}^n |\bar{l}_{nj}(t)|, \text{ где}$$

$$\bar{l}_{nj}(t) = \prod_{k \neq j} \frac{(t - t_k)}{(t_j - t_k)}.$$

Естественно поставить задачу о таком оптимальном выборе узлов интерполяции, чтобы величина  $\Lambda_n$  оказалась минимально возможной. Для малых значений  $n$  эту задачу решить нетрудно. При  $n = 1$  выбор  $t_0 = -1, t_1 = 1$  дает  $\Lambda_1 = 1$ . При  $n = 2$  оптимальное значение  $\Lambda_2 = 5/4$  достигается, например, при  $t_0 = -1, t_1 = 0, t_2 = 1$ . В общем случае оптимальный выбор узлов неизвестен. Установлено, однако, что почти оптимальным является выбор в качестве узлов интерполяции нулей многочлена Чебышева  $T_{n+1}$ . При таком выборе  $\Lambda_n \approx \frac{2}{\pi} \ln(n+1) + 1$ .

С рассматриваемой точки зрения крайне неудачным при больших  $n$  является выбор равноотстоящих узлов интерполяции. При таком выборе  $\Lambda_n > \frac{2^{n-1}}{(2n-1)\sqrt{n}}$  для  $n \geq 4$  и обусловленность задачи резко ухудша-

ется с ростом  $n$ . Сказанное позволяет сделать важный вывод: в вычислениях не следует использовать интерполяционные многочлены высокой степени с равноотстоящими узлами.

**3. Обусловленность задачи вычисления многочлена с приближенно заданными коэффициентами.** Обратим внимание на еще один потенциальный источник потери точности при использовании многочленов  $P_n(x)$  высокой степени. Для определенности будем считать, что многочлен вычисляется на отрезке  $[a, b]$ , где  $|a| < b$ , причем предварительно он представлен в виде

$$P_n(x) = \sum_{k=0}^n a_k \varphi_k(x). \quad (11.62)$$

Здесь  $\{\varphi_k(x)\}_{k=0}^n$  — некоторый набор базисных многочленов  $\varphi_k(x)$ , обладающий тем свойством, что всякий многочлен  $P_n(x)$  степени  $n$  может быть однозначно представлен в виде (11.62). Например, можно ис-

пользовать степенной базис  $\{x^k\}_{k=0}^n$ , нормированный степенной базис  $\left\{\left[\frac{x}{b}\right]^k\right\}_{k=0}^n$ , локальный степенной базис  $\left\{\left[\frac{x-a}{b-a}\right]^k\right\}_{k=0}^n$ , чебышевский базис  $\left\{T_k\left[\frac{x-(a+b)/2}{(b-a)/2}\right]\right\}_{k=0}^n$ , лагранжев базис  $\{l_{nk}(x)\}_{k=0}^n$  (см. § 11.3) и т. д.

При вычислении коэффициентов  $a_k$  неизбежны погрешности, приводящие к приближенным значениям  $a_k^*$ . Поэтому в действительности будет вычисляться многочлен

$$P_n^*(x) = \sum_{k=0}^n a_k^* \varphi_k(x).$$

Примем за относительную погрешность вектора  $\mathbf{a}^* = (a_0^*, a_1^*, \dots, a_n^*)^T$  величину

$$\delta(\mathbf{a}^*) = (\max_{0 \leq i \leq n} |a_i - a_i^*|) / \max_{0 \leq i \leq n} |a_i|,$$

а за относительную погрешность многочлена  $P_n^*(x)$  — величину

$$\delta(P_n^*) = (\max_{[a, b]} |P_n(x) - P_n^*(x)|) / \max_{[a, b]} |P_n(x)|.$$

Число обусловленности задачи вычисления многочлена с приближенно заданными коэффициентами назовем величину  $\text{cond}_n$ , равную минимальной из постоянных  $K_n$ , для которых выполняется неравенство  $\delta(P_n^*) \leq K_n \delta(\mathbf{a}^*)$ .

Величина  $\text{cond}_n$ , характеризующая чувствительность вычисляемых значений многочлена к погрешностям в коэффициентах  $a_k$ , существенно зависит от выбора базиса  $\{\varphi_k(x)\}_{k=0}^n$ . Неудачный выбор базиса может сделать эту, казалось бы, элементарную задачу очень плохо обусловленной. Доказано, например, что даже для вполне "разумного" локального степенного базиса  $\left\{\left[\frac{x-a}{b-a}\right]^k\right\}_{k=0}^n$  число обусловленности оценивается снизу величиной  $T_n(3)$ . Как видно из табл. 11.11, использование указанного базиса для представления многочленов высокой степени сопряжено с опасностью значительной потери точности.

Т а б л и ц а 11.11

$n$	1	2	3	4	5	6	7	8	9
$T_n(3)$	3	17	99	577	3363	19601	114243	665857	3880899

Отметим, что для чебышевского базиса  $\text{cond}_n \leq \sqrt{2}(n+1)$ . Для лагранжева базиса число обусловленности совпадает с константой Лебега  $\Lambda_n$ . Напомним, что при почти оптимальном выборе узлов интерполяции  $\Lambda_n \approx \frac{2}{\pi} \ln(n+1) + 1$ .

Итак, глобальная полиномиальная интерполяция многочленом высокой степени может привести к неудаче или оказаться неэффективной. Альтернативный подход состоит в *локальной интерполяции*, когда функция  $f$  аппроксимируется интерполяционным многочленом  $P_m(x)$  невысокой степени  $m$  на содержащемся в  $[a, b]$  отрезке  $[\alpha, \beta]$  малой длины. Естественно, что при этом используется лишь часть табличных значений. Рассмотрим два подхода к приближению функции, основанные на локальной интерполяции.

**4. Интерполирование с помощью "движущегося" полинома.** Строят набор полиномов  $P_{(0,1, \dots, m)}$ ,  $P_{(1,2, \dots, m+1)}$ , ...,  $P_{(n-m, n-m+1, \dots, n)}$  фиксированной степени  $m$ , каждый из которых совпадает с табличными значениями в  $m+1$  последовательных точках. Каждый такой полином используют для приближения функции в тех точках  $x$  из отрезка  $[a, b]$ , для которых выбранные узлы таблицы являются ближайшими.

**Пример 11.11.** Пусть функция задана следующей таблицей:

Т а б л и ц а 11.12

$i$	0	1	2	3	4
$x_i$	0	1	2	3	4
$y_i$	1.0	1.8	2.2	1.4	1.0

Для интерполяции этой функции воспользуемся "движущимся" полиномом второй степени. Заметим, что при  $x \in [0.0, 1.5]$  для приближения используется многочлен  $P_{(0,1,2)}(x)$ , при  $x \in [1.5, 2.5]$  — многочлен  $P_{(1,2,3)}(x)$ , при  $x \in [2.5, 4.0]$  — многочлен  $P_{(2,3,4)}(x)$ . Соответствующая геометрическая иллюстрация приведена на рис. 11.6. Заметим, что полученная таким способом аппроксимирующая функция имеет разрывы в точках  $x = 1.5$  и  $x = 2.5$ .



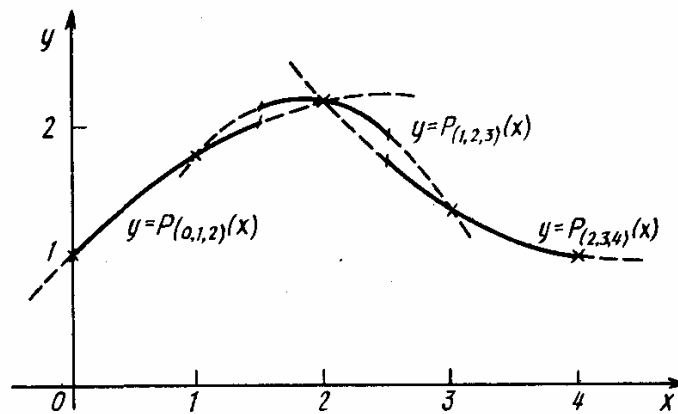


Рис. 11.6

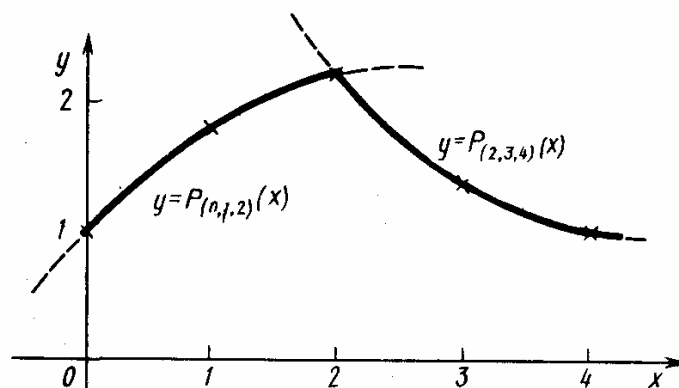


Рис. 11.7

**5. Кусочно-полиномиальная интерполяция.** Исходный отрезок  $[a, b]$  разбивают на несколько отрезков меньшей длины, на каждом из которых функция интерполируется своим многочленом.

**Пример 11.12.** Для интерполяции функции из примера 11.11 используем кусочно-полиномиальную интерполяцию. На отрезке  $[0, 2]$  аппроксимируем функцию многочленом  $P_{(0,1,2)}(x)$ , а на отрезке  $[2, 4]$  — многочленом  $P_{(2,3,4)}(x)$ . Соответствующая геометрическая иллюстрация приведена на рис. 11.7. Заметим, что результирующая аппроксимирующая функция непрерывна, но в точке  $x = 2$  график ее имеет излом, соответствующий разрыву первой производной.

Заметим, что интерполяцию "движущимся" полиномом можно рассматривать как частный случай кусочно-полиномиальной интерполяции.

Как следует из оценки (11.30), метод кусочно-полиномиальной интерполяции при использовании многочленов фиксированной степени  $m$  имеет  $(m + 1)$ -й порядок точности относительно  $h_{\max}$ .

## § 11.11. Интерполяция сплайнами

**1. Определение сплайна.** Проведенное выше обсуждение интерполяции показывает, что повышение точности приближения гладкой функции благодаря увеличению степени интерполяционного многочлена возможно (см. теорему 11.8), но связано с существенным повышением сложности вычислений. К тому же использование многочленов высокой степени требует специальных мер предосторожности уже при выборе формы их записи, и вычисления сопровождаются накоплением ошибок округления.

Поэтому на практике предпочитают кусочно-полиномиальную интерполяцию с использованием многочленов невысокой степени. Однако этот способ приближения имеет недостаток: в точках "стыка" двух соседних многочленов производная, как правило, имеет разрыв (см. пример 11.12). Часто это обстоятельство не играет существенной роли. Вместе с тем нередко требуется, чтобы аппроксимирующая функция была гладкой и тогда простейшая кусочно-полиномиальная интерполяция становится неприемлемой.

Естественная потребность в наличии аппроксимирующих функций, которые сочетали бы в себе локальную простоту многочлена невысокой степени и глобальную на всем отрезке  $[a, b]$  гладкость, привела к появлению в 1946 г. так называемых *сплайн-функций* или *сплайнов* — специальным образом построенных гладких кусочно-многочленных функций. Получив в 60-х годах распространение как средство интерполяции сложных кривых, сплайны к настоящему времени стали важной составной частью самых различных вычислительных методов и нашли широчайшее применение в решении разнообразных научно-технических и инженерных задач.

Дадим строгое определение сплайна. Пусть отрезок  $[a, b]$  разбит точками  $a = x_0 < x_1 < \dots < x_n = b$  на  $n$  частичных отрезков  $[x_{i-1}, x_i]$ . *Сплайном степени  $m$*  называется функция  $S_m(x)$ , обладающая следующими свойствами:

1) функция  $S_m(x)$  непрерывна на отрезке  $[a, b]$  вместе со всеми своими производными  $S_m^{(1)}(x), S_m^{(2)}(x), \dots, S_m^{(p)}(x)$  до некоторого порядка  $p$ ;

2) на каждом частичном отрезке  $[x_{i-1}, x_i]$  функция  $S_m(x)$  совпадает с некоторым алгебраическим многочленом  $P_{m,i}(x)$  степени  $m$ .

Разность  $m - p$  между степенью сплайна и наивысшим порядком непрерывной на отрезке  $[a, b]$  производной называется *дефектом сплайна*.

Простейший пример сплайна дает непрерывная кусочно-линейная

функция (рис. 11.8), являющаяся сплайном первой степени (*линейным сплайном*) с дефектом, равным единице. Действительно, на отрезке  $[a, b]$  сама функция  $S_1(x)$  (нулевая производная) непрерывна. В то же время на каждом частичном отрезке  $S_1(x)$  совпадает с некоторым многочленом первой степени.

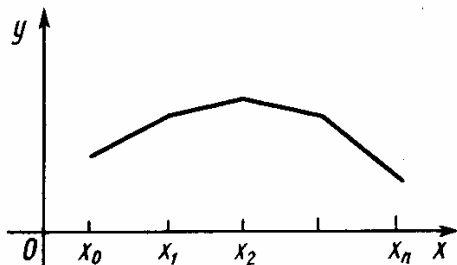


Рис. 11.8

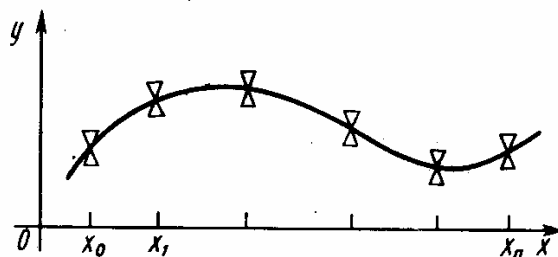


Рис. 11.9

Наиболее широкое распространение на практике получили сплайны  $S_3(x)$  третьей степени (*кубические сплайны*) с дефектом, равным 1 или 2. Такие сплайны на каждом из частичных отрезков  $[x_{i-1}, x_i]$  совпадают с кубическим многочленом:

$$S_3(x) = P_{3,i}(x) = a_i + b_i(x - x_{i-1}) + c_i(x - x_{i-1})^2 + d_i(x - x_{i-1})^3 \quad (11.63)$$

и имеют на отрезке  $[a, b]$  по крайней мере одну непрерывную производную  $S'_3(x)$ .

Термин "сплайн" происходит от английского слова "spline" (гибкая линейка, стержень) — названия приспособления, использовавшегося чертежниками для проведения гладких кривых через заданные точки. Если гибкую стальную линейку поставить на ребро и, изогнув, зафиксировать ее положение в узловых точках (рис. 11.9), то получится механический аналог кубического сплайна. В самом деле, из курса сопротивления материалов известно, что уравнение свободного равновесия профиля  $S(x)$  линейки таково:  $S^{(4)}(x) = 0$ . Следовательно, в промежутке между двумя соседними узлами  $S(x)$  представляет собой многочлен третьей степени. В то же время отсутствие у линейки изломов свидетельствует о непрерывности касательной к графику функции  $S(x)$  и кривизны, т. е. производных  $S'(x)$  и  $S''(x)$ .

**2. Интерполяционный сплайн.** Пусть функция  $y = f(x)$  задана таблицей своих значений  $y_i = f(x_i)$ ,  $i = 0, 1, \dots, n$ . Сплайн  $S_m(x)$  называется *интерполяционным*, если  $S_m(x_i) = y_i$  для всех  $i = 0, 1, \dots, n$ . Значение  $s_i = S'_m(x_i)$  называется *наклоном сплайна* в точке  $x_i$ .

Заметим, что на отрезке  $[x_{i-1}, x_i]$  интерполяционный кубический сплайн однозначно определяется заданием значений  $y_{i-1}$ ,  $y_i$ ,  $s_{i-1}$ ,  $s_i$ . В самом деле, из равенства (11.31) вытекает следующая формула:

$$S_3(x) = P_{3,i}(x) = \frac{(x-x_i)^2(2(x-x_{i-1})+h_i)}{h_i^3} y_{i-1} + \frac{(x-x_{i-1})^2(2(x-x_i)+h_i)}{h_i^3} y_i + \\ + \frac{(x-x_i)^2(x-x_{i-1})}{h_i^2} s_{i-1} + \frac{(x-x_{i-1})^2(x-x_i)}{h_i^2} s_i. \quad (11.64)$$

Здесь  $h_i = x_i - x_{i-1}$ .

Различные методы интерполяции кубическими сплайнами отличаются один от другого способом выбора наклонов  $s_i$ . Обсудим некоторые из них.

**3. Локальный сплайн.** Если в точках  $x_i$  известны значения производной  $y'_i = f'(x_i)$ , то естественно положить  $s_i = y'_i$  для всех  $i = 0, 1, \dots, n$ . Тогда на каждом частичном отрезке  $[x_{i-1}, x_i]$  в соответствии с формулой (11.64) сплайн однозначно определяется значениями  $y_{i-1}, y_i, y'_{i-1}, y'_i$  (поэтому его и называют *локальным сплайном*). Заметим, что он совпадает с кубическим интерполяционным многочленом Эрмита (11.31) для отрезка  $[x_{i-1}, x_i]$ .

Из неравенства (11.33) получается следующая оценка погрешности интерполяции локальным кубическим сплайном:

$$\max_{[a, b]} |f(x) - S_3(x)| \leq \frac{M_4}{384} h_{\max}^4, \quad (11.65)$$

где  $h_{\max} = \max_{1 \leq i \leq n} h_i$  — максимальная из длин частичных отрезков.

Заметим, что для построенного указанным образом сплайна можно гарантировать непрерывность на отрезке  $[a, b]$  только функции  $S_3$  и ее первой производной  $S'_3$ , т.е. его дефект равен 2.

Существуют и другие способы выбора коэффициентов  $s_i$ , приводящие к локальным сплайнам (кубический многочлен Бесселя<sup>1</sup>, метод Акимы и др. [16]).

**4. Глобальные способы построения кубических сплайнов.** Для того чтобы сплайн  $S_3(x)$  имел непрерывную на отрезке  $[a, b]$  вторую производную  $S''_3(x)$ , необходимо выбирать наклоны  $s_i$  так, чтобы в точках  $x_i$  "стыка" многочленов  $P_{3,i}$  и  $P_{3,i+1}$  совпадали значения их вторых производных:

$$P''_{3,i}(x_i) = P''_{3,i+1}(x_i), \quad i = 1, 2, \dots, n-1. \quad (11.66)$$

---

<sup>1</sup> Фридрих Вильгельм Бессель (1784—1846) — немецкий астроном.

Пользуясь формулой (11.64), найдем значение

$$P''_{3,i}(x_i) = \frac{2s_{i-1}}{h_i} + \frac{4s_i}{h_i} - 6 \frac{y_i - y_{i-1}}{h_i^2}. \quad (11.67)$$

Из подобной формулы, записанной для многочлена  $P_{3,i+1}$ , имеем

$$P''_{3,i+1}(x_i) = -\frac{4s_i}{h_{i+1}} - \frac{2s_{i+1}}{h_{i+1}} + 6 \frac{y_{i+1} - y_i}{h_{i+1}^2}. \quad (11.68)$$

Таким образом, равенства (11.66) приводят к следующей системе уравнений относительно коэффициентов  $s_i$ :

$$h_i^{-1}s_{i-1} + 2(h_i^{-1} + h_{i+1}^{-1})s_i + h_{i+1}^{-1}s_{i+1} = 3[h_i^{-2}(y_i - y_{i-1}) + h_{i+1}^{-2}(y_{i+1} - y_i)], \\ i = 1, 2, \dots, n-1. \quad (11.69)$$

Заметим, что эта система уравнений недоопределена, так как число уравнений системы (равное  $n-1$ ) меньше числа неизвестных (равного  $n+1$ ). Выбор двух оставшихся уравнений обычно связывают с некоторыми дополнительными условиями, накладываемыми на сплайн в граничных точках  $a$  и  $b$  (*граничными условиями*). Укажем на некоторые из наиболее известных граничных условий.

1°. Если в граничных точках известны значения первой производной  $f'(a)$  и  $f'(b)$ , то естественно положить

$$s_0 = f'(a), \quad s_n = f'(b). \quad (11.70)$$

Дополняя систему (11.69) уравнениями (11.70), приходим к системе уравнений с трехдиагональной матрицей, которая легко решается методом прогонки (см. гл. 5). Полученный таким образом сплайн называется *фундаментальным кубическим сплайном*.

2°. Если в граничных точках известны значения второй производной  $f''(a)$  и  $f''(b)$ , то можно наложить на сплайн граничные условия  $S''_3(a) = P''_{3,1}(x_0) = f''(a)$ ,  $S''_3(b) = P''_{3,n}(x_n) = f''(b)$ , что приводит к следующим уравнениям:

$$-\frac{4s_0}{h_1} - \frac{2s_1}{h_1} + 6 \frac{y_1 - y_0}{h_1^2} = f''(a), \quad (11.71)$$

$$\frac{2s_{n-1}}{h_n} + \frac{4s_n}{h_n} - 6 \frac{y_n - y_{n-1}}{h_n^2} = f''(b) \quad (11.72)$$

(достаточно в равенстве (11.68) взять  $i = 0$ , а в равенстве (11.67)  $i = n$ ).

3°. Полагая в уравнениях (11.71), (11.72)  $f''(a) = 0$ ,  $f''(b) = 0$  (независимо от того, выполнены ли эти условия для интерполируемой функции), придем к системе уравнений, определяющих так называемый *естественный кубический сплайн*.

4°. Часто нет, никакой дополнительной информации о значениях производных на концах отрезка. Один из применяемых в этой ситуации подходов состоит в использовании условия "отсутствия узла". Выбор наклонов  $s_i$  производят таким образом, чтобы для получаемого сплайна выполнялись условия  $P_{3,1}(x) \equiv P_{3,2}(x)$ ,  $P_{3,n-1}(x) \equiv P_{3,n}(x)$ . Для этого достаточно потребовать совпадения в точках  $x_1$  и  $x_{n-1}$  соответствующих третьих производных:

$$P_{3,1}^{(3)}(x_1) = P_{3,2}^{(3)}(x_1), \quad P_{3,n-1}^{(3)}(x_{n-1}) = P_{3,n}^{(3)}(x_{n-1}).$$

Эквивалентные алгебраические уравнения выглядят так:

$$2h_1^{-3}(y_0 - y_1) + h_1^{-2}(s_0 + s_1) = 2h_2^{-3}(y_1 - y_2) + h_2^{-2}(s_1 + s_2), \quad (11.73)$$

$$\begin{aligned} 2h_{n-1}^{-3}(y_{n-2} - y_{n-1}) + h_{n-1}^{-2}(s_{n-2} + s_{n-1}) = \\ = 2h_n^{-3}(y_{n-1} - y_n) + h_n^{-2}(s_{n-1} + s_n). \end{aligned} \quad (11.74)$$

Та же аппроксимирующая функция может быть получена несколько иначе. Уменьшим число частичных отрезков, объединив попарно отрезки  $[x_0, x_1]$ ,  $[x_1, x_2]$  и  $[x_{n-2}, x_{n-1}]$ ,  $[x_{n-1}, x_n]$ . Это отвечает разбиению отрезка  $[a, b]$  точками  $a = \tilde{x}_0 < \tilde{x}_1 < \dots < \tilde{x}_{n-2} = b$ , где  $\tilde{x}_i = x_{i+1}$  для  $i = 1, 2, \dots, n-3$ , и построению соответствующего интерполяционного сплайна  $\tilde{S}_3(x)$ . Условия "отсутствия узла" эквивалентны требованию совпадения значений сплайна  $\tilde{S}_3(x)$  в точках  $x_1$  и  $x_{n-1}$  со значениями  $y_1$  и  $y_{n-1}$ .

5°. Если  $f$  — периодическая функция с периодом, равным  $b - a$ , то систему (11.69) следует дополнить условиями

$$s_0 = s_n,$$

$$h_n^{-1}(s_{n-1} + 2s_n) + h_1^{-1}(2s_0 + s_1) = 3[h_n^{-2}(y_n - y_{n-1}) + h_1^{-2}(y_1 - y_0)].$$

Существуют и другие подходы к заданию граничных условий (подробнее об этом см. [16]).

**Пример 11.13.** Для функции, заданной табл. 11.12, построим (естественный) кубический сплайн. В этом случае система уравнений для наклонов  $s_0, s_1, \dots, s_4$  в точках  $x_0, x_1, \dots, x_4$  записывается следующим образом:

$$s_0 = -0.5s_1 + 1.2, \quad (11.75)$$

$$s_0 + 4s_1 + s_2 = 3.6, \quad (11.76)$$

$$s_1 + 4s_2 + s_3 = -1.2, \quad (11.77)$$

$$s_2 + 4s_3 + s_4 = -3.6, \quad (11.78)$$

$$s_4 = -0.5s_3 - 0.6. \quad (11.79)$$

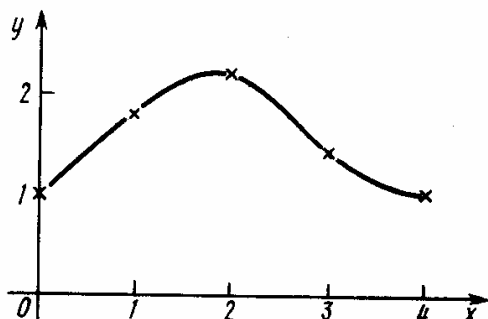


Рис. 11.10

Решая ее, получаем значения  $s_0 = 57/70$ ,  $s_1 = 54/70$ ,  $s_2 = -3/10$ ,  $s_3 = -54/70$ ,  $s_4 = -3/14$ . Теперь на каждом частичном отрезке значения сплайна можно вычислить по формуле (11.64). Соответствующий график приведен на рис. 11.10 (ср. с рис. 11.6 и 11.7).

**Пример 11.14.** Интерполируем функцию, заданную табл. 11.12, кубическим сплайном, используя условие "отсутствия узла". В этом случае уравнения (11.76)–

(11.78) останутся прежними, а уравнения (11.75) и (11.79) заменяются следующими:

$$s_0 - s_2 = 0.8, \quad s_2 - s_4 = -0.8. \quad (11.80)$$

Решая систему (11.76)–(11.78), (11.80), получаем значения  $s_0 = 8/15$ ,  $s_1 = 5/6$ ,  $s_2 = -4/15$ ,  $s_3 = -29/30$ ,  $s_4 = 8/15$ . График соответствующего сплайна мало отличается от графика, изображенного на рис. 11.10.

### 5. Погрешность приближения кубическими сплайнами.

**Теорема 11.9.** Пусть функция  $f$  имеет на отрезке  $[a, b]$  непрерывную производную четвертого порядка и  $M_4 = \max_{[a, b]} |f^{(4)}(x)|$ . Тогда

для интерполяционного кубического сплайна  $S_3(x)$ , удовлетворяющего граничным условиям типов  $1^0$ ,  $2^0$ ,  $4^0$  или  $5^0$  (последнее — для случая периодической функции), справедлива следующая оценка погрешности:

$$\max_{[a, b]} |f(x) - S_3(x)| \leq CM_4 h_{\max}^4. \quad (11.81)$$

Заметим, что сплайн  $S_3(x)$  не только сам аппроксимирует функцию  $f(x)$ , но его производные  $S_3'(x)$ ,  $S_3''(x)$ ,  $S_3^{(3)}(x)$  приближают соответствующие производные функции  $f$ . Сформулируем соответствующую теорему в наиболее простом случае, когда таблица задана с постоянным шагом  $h$ .

**Теорема 11.10.** При выполнении условий теоремы 11.9 для указанных в ней сплайнов справедливы неравенства

$$\max_{[a, b]} |f^{(k)}(x) - S_3^{(k)}(x)| \leq C_k M_4 h^{4-k}, \quad k = 1, 2, 3. \quad (11.82)$$

**З а м е ч а н и е.** Благодаря большей простоте записи и благозвучному названию естественные сплайны получили значительное распространение. Однако искусственное наложение условий  $f''(a) = 0$ ,  $f''(b) = 0$  при интерполяции функций, которые этим условиям не удовлетворяют, приводит к значительной потере точности. Вместо четвертого порядка точности (как локальный кубический сплайн или кубические сплайны с граничными условиями типов  $1^0$ ,  $2^0$ ,  $4^0$ ,  $5^0$ ) естественный сплайн обладает лишь вторым порядком точности. Если использование естественного сплайна не вызвано какими-либо специальными причинами, то следует, по-видимому, отказаться от него в пользу кубического сплайна с граничным условием типа  $4^0$ .

## § 11.12. Понятие о дискретном преобразовании Фурье и тригонометрической интерполяции

**1. Дискретное преобразование Фурье.** В прикладных исследованиях широко используются различные варианты преобразования Фурье<sup>1</sup> функций непрерывного аргумента, а также представление функций в виде сходящихся тригонометрических рядов (рядов Фурье). Известно, например, что всякая непрерывно дифференцируемая периодическая с периодом 1 функция  $f$  может быть разложена в ряд Фурье:

$$f(x) = \sum_{k=-\infty}^{\infty} \alpha_k \exp\{2\pi i k x\}. \quad (11.83)$$

Здесь  $i$  — мнимая единица. Коэффициенты разложения вычисляются по формулам

$$\alpha_k = \int_0^1 f(x) \exp\{-2\pi i k x\} dx. \quad (11.84)$$

Однако во многих случаях функция  $f$  бывает задана лишь в конечном числе точек  $x_j = j/N$ ,  $j = 0, 1, \dots, N-1$ . В этом случае аналогом формулы (11.83) является разложение вида

$$f(x_j) = \sum_{k=0}^{N-1} \alpha_k \exp\{2\pi i k x_j\}, \quad 0 \leq j < N. \quad (11.85)$$

---

<sup>1</sup> Жан Батист Жозеф Фурье (1768—1830) — французский математик, один из основоположников математической физики.



Заметим, что это разложение имеет место тогда и только тогда, когда тригонометрический многочлен

$$S_N(x) = \sum_{k=0}^{N-1} a_k \exp\{2\pi i k x\} \quad (11.86)$$

интерполирует функцию  $f$  по ее значениям в точках  $x_j$ ,  $0 \leq j < N$ . Выше (см. пример 11.2) было доказано, что система функций  $\varphi_k(x) = \exp\{2\pi i k x\}$ ,  $0 \leq k < N$  ортогональна на множестве точек  $x_j = j/N$ ,  $0 \leq j < N$ , причем  $(\varphi_k, \varphi_k) = N$ . Следовательно, разложение (11.85) действительно имеет место, причем в силу равенства (11.19) коэффициенты  $a_k$  определяются по формуле

$$a_k = \frac{1}{N} \sum_{l=0}^{N-1} f(x_l) \exp\{-2\pi i k x_l\}, \quad 0 \leq k < N. \quad (11.87)$$

Операцию преобразования набора значений  $f(x_0), f(x_1), \dots, f(x_{N-1})$  в набор коэффициентов  $a_0, a_1, \dots, a_{N-1}$  принято называть *прямым дискретным преобразованием Фурье*, а обратную операцию — *обратным дискретным преобразованием Фурье*. Осуществление этих операций является важной составной частью многих алгоритмов.

Для удобства изложения введем обозначение  $\omega = \exp\{2\pi i/N\}$  и перепишем формулы (11.85), (11.87) в следующем виде:

$$f(x_j) = \sum_{k=0}^{N-1} a_k \omega^{kj}, \quad 0 \leq j < N, \quad (11.88)$$

$$a_k = \frac{1}{N} \sum_{l=0}^{N-1} f(x_l) \omega^{-kl}, \quad 0 \leq k < N. \quad (11.89)$$

**2. Быстрое дискретное преобразование Фурье.** Если вычисления проводить непосредственно по формулам (11.88) и (11.89), то на выполнение каждого из преобразований потребуется примерно  $N^2$  арифметических операций. (Здесь под арифметической операцией понимается умножение двух комплексных чисел с последующим сложением. Величины  $\omega^{kj}$  считаются вычисленными заранее.)

Однако в случае, когда число  $N$  не является простым, количество арифметических операций, требуемых для вычисления по формулам (11.88) и (11.89), можно существенно уменьшить. Поясним сказанное на примере вычислений по формулам (11.88). (Вычисления по формулам (11.89) производятся аналогично с заменой  $\omega$  на  $\omega^{-1}$ .)

Пусть  $N = N_1 N_2$ , где  $2 \leq N_1$ ,  $2 \leq N_2$  — целые числа. Представим индекс  $j$  в виде  $j = j_1 N_1 + j_0$ , где  $0 \leq j_1 < N_2$ ,  $0 \leq j_0 < N_1$ . Положим  $k =$

$= k_1 N_2 + k_0$ , где  $0 \leq k_1 < N_1$ ,  $0 \leq k_0 < N_2$ . Пользуясь тем, что  $kj = k_1 j_1 N + k_1 j_0 N_2 + k_0 j$  и  $\omega^{k_1 j_1 N} = 1$ , имеем  $\omega^{kj} = \omega^{k_1 j_0 N_2} \omega^{k_0 j}$ . Заменяя в формуле (11.88) суммирование по индексу  $k$  операцией повторного суммирования по индексам  $k_0$  и  $k_1$ , получим

$$f(x_j) = \sum_{k_0=0}^{N_2-1} \sum_{k_1=0}^{N_1-1} a_{k_1 N_2 + k_0} \omega^{k_1 j_0 N_2} \omega^{k_0 j} = \sum_{k_0=0}^{N_2-1} \tilde{a}(k_0, j_0) \omega^{k_0 j}, \quad (11.90)$$

где

$$\tilde{a}(k_0, j_0) = \sum_{k_1=0}^{N_1-1} a_{k_1 N_2 + k_0} \omega^{k_1 j_0 N_2}. \quad (11.91)$$

Массив  $\tilde{a}$  содержит  $N$  чисел и для его вычисления требуется  $NN_1$  арифметических операций. После того как найдены значения  $\tilde{a}(k_0, j_0)$ , на вычисления по формуле (11.90) требуется  $NN_2$  операций. Таким образом, общее число арифметических операций равно  $N(N_1 + N_2)$ . Заметим, что достигнута экономия в числе операций, поскольку  $N_1 + N_2 < N_1 N_2 = N$ , как только  $N > 4$ . Выигрыша удалось достичь благодаря тому, что оказалось возможным выделить группы слагаемых (11.91), которые используются для вычисления значений  $f(x_j)$  при различных  $j$ , но сами вычисляются лишь однажды.

Указанная выше идея развита в алгоритмах *быстрого дискретного преобразования Фурье*. В случае, когда  $N = N_1 \cdot N_2 \dots N_m$ , (где  $2 \leq N_s$ ), с помощью быстрого дискретного преобразования Фурье можно выполнить дискретное преобразование Фурье за  $N(N_1 + N_2 + \dots + N_m)$  арифметических операций. Особенно эффективным является этот алгоритм, когда число  $N$  является степенью числа 2 (т. е.  $N = 2^m$ ). В этом случае вместо  $N^2$  операций требуется выполнить лишь  $2N \log_2 N$  операций. Например, для  $N = 1024 = 2^{10}$  этот алгоритм позволяет ускорить вычисления в  $\frac{N}{2 \log_2 N} = 1024/20 \approx 50$  раз.

Широкое внедрение алгоритма быстрого дискретного преобразования Фурье в практические вычисления привело к подлинной революции во многих областях, связанных с обработкой числовой информации. Программы, реализующие различные варианты этого алгоритма, входят в стандартное математическое обеспечение ЭВМ и доступны массовому пользователю.

**З а м е ч а н и е 1.** Часто разложение (11.85) записывают в эквивалентном виде:

$$f(x_j) = \sum_{-N/2 < k \leq N/2} a_k \exp\{2\pi i k x_j\},$$

что соответствует интерполяции тригонометрическим многочленом

$$S_N(x) = \sum_{-N/2 < k \leq N/2} a_k \exp\{2\pi i k x\} \quad (11.92)$$

Здесь коэффициенты  $a_k$  по-прежнему задаются формулой (11.87).

**З а м е ч а н и е 2.** Хотя интерполяционные тригонометрические многочлены (11.86), (11.92) и совпадают в точках  $x_j$ , они принимают существенно разные значения в точках  $x$ , отличных от узловых.

**3. Тригонометрическая интерполяция.** Рассмотрим кратко задачу интерполяции функции  $f$ , заданной в точках  $0 \leq x_0 < x_1 < \dots < x_{N-1} \leq 1$  тригонометрическим многочленом (11.92). К ней приводит, например, типичная радиотехническая задача о тригонометрической интерполяции периодического сигнала.

Не вдаваясь в довольно сложную проблему оценки погрешности тригонометрической интерполяции, отметим тем не менее, что для гладкой периодической с периодом 1 функции  $f$  есть основание рассчитывать на выполнение приближенного равенства  $f(x) \approx S_N(x)$  для всех  $x \in [0, 1]$ .

Рассмотрим важный вопрос о чувствительности многочлена  $S_N$  к погрешностям в исходных данных. Пусть значения  $y_i^* \approx f(x_i)$  интерполируемой функции задаются с погрешностями  $\epsilon_i$  и известно, что  $|\epsilon_i| \leq \bar{\Delta}(y^*)$  для  $i = 0, 1, \dots, N-1$ . Тогда вычисляемый по значениям  $y_i^*$  тригонометрический интерполяционный многочлен  $S_n^*$  содержит погрешность. Для нее справедлива оценка

$$\bar{\Delta}(S_N^*) = \max_{[0, 1]} |S_N^*(x) - S_N(x)| \leq \tilde{\Lambda}_N \bar{\Delta}(y^*),$$

аналогичная оценке (11.61) для алгебраических многочленов. Здесь  $\tilde{\Lambda}_N$  — постоянная, являющаяся аналогом константы Лебега  $\Lambda_N$ .

Примечательно то, что в отличие от задачи интерполяции алгебраическими многочленами (см. § 11.10) оптимальным (т. е. дающим минимальное значение  $\tilde{\Lambda}_N$ ) является равномерное распределение узлов, которому отвечает значение  $\tilde{\Lambda}_N \approx \frac{2}{\pi} \ln [(N+1)/2]$ .

Таким образом, при тригонометрической интерполяции выбор узлов  $x_j = j/N$  ( $0 \leq j < N$ ) является наиболее естественным с точки зрения как простоты вычисления коэффициентов многочлена (быстрое дискретное преобразование Фурье), так и минимизации влияния ошибок исходных данных.

### § 11.13. Метод наименьших квадратов

Задача наименьших квадратов возникает в самых различных областях науки и техники. Например, к ней приходят при статистической обработке экспериментальных данных с помощью регрессионного анализа. В инженерной деятельности задача наименьших квадратов используется в таких областях, как оценивание параметров и фильтрация.

**1. Линейная задача наименьших квадратов.** Пусть функция  $y = f(x)$  задана таблицей приближенных значений

$$y_i \approx f(x_i), \quad i = 0, 1, \dots, n, \quad (11.93)$$

полученных с ошибками  $\varepsilon_i = y_i^0 - y_i$ , где  $y_i^0 = f(x_i)$ . Если значения  $y_i$  получены из эксперимента, то ошибки носят случайный характер и зачастую уровень погрешности ("шума" таблицы) бывает значительным (рис. 11.11, а).

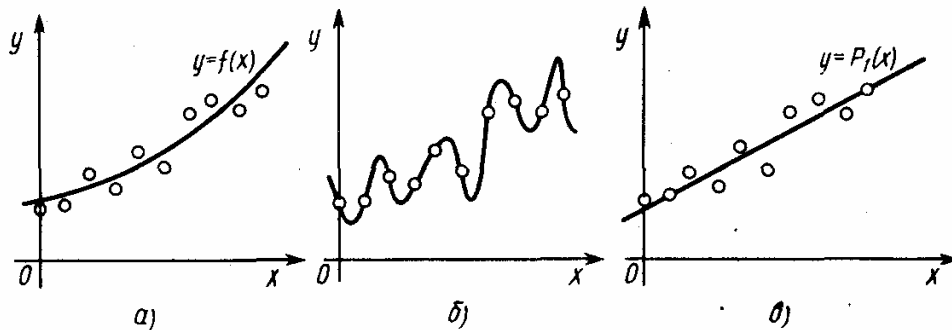


Рис. 11.11

Предположим, что для аппроксимации функции  $f$  используется линейная модель:

$$y = \Phi_m(x) \equiv a_0\varphi_0(x) + a_1\varphi_1(x) + \dots + a_m\varphi_m(x). \quad (11.94)$$

Здесь  $\varphi_0(x), \varphi_1(x), \dots, \varphi_m(x)$  — заданные базисные функции<sup>1</sup>,  $a_0, a_1, \dots$ ,

<sup>1</sup> В данном параграфе рассматриваются функции, принимающие только вещественные значения.



$$s(a, y) = \sum_{i=0}^n \sum_{j=0}^m (a_j \varphi_j(x_i) - y_i)^2 = \|Pa - y\|^2,$$

причем

$$\delta(\Phi_m, y)^2 = \frac{1}{n+1} s(a, y).$$

Итак, *линейная задача метода наименьших квадратов* состоит в следующем. Требуется найти (при фиксированном наборе функций  $\varphi_0, \varphi_1, \dots, \varphi_m$ ) обобщенный многочлен  $\Phi_m^y(x)$ , для которого среднеквадратичное отклонение принимает минимальное значение:

$$\delta(\Phi_m^y, y) = \min_{\Phi_m} \delta(\Phi_m, y).$$

Искомый обобщенный многочлен  $\Phi_m^y$  будем далее называть *многочленом наилучшего среднеквадратичного приближения*.

**2. Нормальная система.** Существуют различные подходы к решению поставленной задачи. Простейший из них состоит в использовании необходимого условия экстремума функции  $s$ :

$$\frac{\partial s}{\partial a_k} = 0, \quad k = 0, 1, \dots, m \quad (11.98)$$

Вычисляя частные производные функции  $s$  и изменяя порядок суммирования, от равенства (11.98) переходим к системе линейных алгебраических уравнений

$$\sum_{j=0}^m \left( \sum_{i=0}^n \varphi_j(x_i) \varphi_k(x_i) \right) a_j = \sum_{i=0}^n y_i \varphi_k(x_i) \quad (k = 0, 1, \dots, m), \quad (11.99)$$

которая называется *нормальной системой метода наименьших квадратов*.

Как нетрудно видеть, нормальную систему можно записать в виде

$$P^T P a = P^T y, \quad (11.100)$$

или, используя матрицу Грама  $\Gamma = P^T P$  (см. § 11.2) и вводя вектор  $b = P^T y$ , в виде

$$\Gamma a = b. \quad (11.101)$$

**Лемма 11.1.** Пусть  $a$  — решение системы (11.101). Тогда для любого  $a' = a + \Delta a$  имеет место равенство

$$s(a', y) = s(a, y) + \|P \Delta a\|^2.$$

□ Имеем

$$s(a', y) = |P(a + \Delta a) - y|^2 = |Pa - y|^2 + 2(Pa - y, P\Delta a) + |P\Delta a|^2 = s(a, y) + 2(P^T Pa - P^T y, \Delta a) + |P\Delta a|^2.$$

Остается заметить, что второе слагаемое в правой части полученного равенства в силу (11.100) равно нулю. ■

**Теорема 11.11.** Пусть система функций  $\varphi_0, \varphi_1, \dots, \varphi_m$  линейно независима в точках  $x_0, x_1, \dots, x_n$ . Тогда многочлен наилучшего среднеквадратичного приближения  $\Phi_n^y$  существует и единствен.

□ В силу теоремы 11.1  $\det \Gamma \neq 0$ . Поэтому решение  $a$  системы (11.101) существует и единственно. Таким образом, если многочлен  $\Phi_n^y$  существует, то его коэффициенты  $a_0, a_1, \dots, a_m$  определяются единственным образом.

Заметим теперь, что согласно лемме 11.1 для любого  $a' \neq a$  имеем  $s(a', y) \geq s(a, y)$ , т. е. на решении  $a$  нормальной системы действительно достигается минимум функции  $s$ . ■

**З а м е ч а н и е 1.** Если  $m = n$  и система функций  $\varphi_0, \varphi_1, \dots, \varphi_n$  линейно независима в точках  $x_0, x_1, \dots, x_n$ , то многочлен  $\Phi_n^y$ , найденный методом наименьших квадратов, совпадает с интерполяционным многочленом  $\Phi_n$ . В самом деле,  $\Phi_n(x_i) = y_i$  для всех  $i = 0, 1, \dots, n$  и поэтому  $\delta(\Phi_n, y) = 0$ . Так как среднеквадратичное отклонение не может быть отрицательным, то  $\Phi_n$  — многочлен наилучшего среднеквадратичного приближения. В силу его единственности

$$\Phi_n = \Phi_n^y.$$

**З а м е ч а н и е 2.** Как правило, при использовании метода наименьших квадратов предполагается, что  $m \leq n$ . В этом случае метод обладает некоторыми сглаживающими свойствами.

Очень часто для приближения по методу наименьших квадратов используются алгебраические многочлены степени  $m \leq n$ . Поскольку система функций  $1, x, \dots, x^m$  линейно независима в точках  $x_0, x_1, \dots, x_n$  при  $m \leq n$  (см. пример 11.1), в силу теоремы 11.11 алгебраический многочлен наилучшего среднеквадратичного приближения существует и единствен.

Так как в случае приближения алгебраическими многочленами  $\varphi_k(x) = x^k$ , то нормальная система (11.99) принимает следующий вид:

$$\sum_{j=0}^m \left( \sum_{i=0}^n x_i^{j+k} \right) a_j = \sum_{i=0}^n y_i x_i^k, \quad k = 0, 1, \dots, m. \quad (11.102)$$

Запишем систему (11.102) в развернутом виде в двух наиболее простых случаях  $m = 1$  и  $m = 2$ . В случае, когда приближение осуществляется многочленом первой степени  $P_1(x) = a_0 + a_1x$ , нормальная система имеет вид

$$\begin{aligned}(n+1)a_0 + \left[ \sum_{i=0}^n x_i \right] a_1 &= \sum_{i=0}^n y_i, \\ \left[ \sum_{i=0}^n x_i \right] a_0 + \left[ \sum_{i=0}^n x_i^2 \right] a_1 &= \sum_{i=0}^n y_i x_i.\end{aligned}\tag{11.103}$$

Если же используется многочлен второй степени  $P_2(x) = a_0 + a_1x + a_2x^2$ , то нормальная система имеет вид

$$\begin{aligned}(n+1)a_0 + \left[ \sum_{i=0}^n x_i \right] a_1 + \left[ \sum_{i=0}^n x_i^2 \right] a_2 &= \sum_{i=0}^n y_i, \\ \left[ \sum_{i=0}^n x_i \right] a_0 + \left[ \sum_{i=0}^n x_i^2 \right] a_1 + \left[ \sum_{i=0}^n x_i^3 \right] a_2 &= \sum_{i=0}^n y_i x_i, \\ \left[ \sum_{i=0}^n x_i^2 \right] a_0 + \left[ \sum_{i=0}^n x_i^3 \right] a_1 + \left[ \sum_{i=0}^n x_i^4 \right] a_2 &= \sum_{i=0}^n y_i x_i^2.\end{aligned}\tag{11.104}$$

**Пример 11.15.** Пусть функция  $y = f(x)$  задана следующей таблицей:

Т а б л и ц а 11.13

$x$	0.0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
$y$	0.21	0.23	0.31	0.29	0.42	0.35	0.58	0.61	0.59	0.66

Используя метод наименьших квадратов, аппроксимируем ее многочленами первой и второй степени и найдем соответствующие среднеквадратичные отклонения  $\delta_1$  и  $\delta_2$ .

Вычислим коэффициенты и правые части нормальных систем (11.103), (11.104):  $\sum_{i=0}^9 x_i = 4.5$ ,  $\sum_{i=0}^9 x_i^2 = 2.85$ ,  $\sum_{i=0}^9 x_i^3 = 2.025$ ,  $\sum_{i=0}^9 x_i^4 = 1.5333$ ,  $\sum_{i=0}^9 y_i = 4.25$ ,  $\sum_{i=0}^9 y_i x_i = 2.356$ ,  $\sum_{i=0}^9 y_i x_i^2 = 1.6154$ .

Для многочлена первой степени нормальная система имеет вид

$$\begin{aligned}10a_0 + 4.5a_1 &= 4.25, \\ 4.5a_0 + 2.85a_1 &= 2.356.\end{aligned}$$



Решив ее, получим значения  $a_0 \approx 0.183$ ,  $a_1 \approx 0.538$  коэффициентов многочлена  $P_1(x) = a_0 + a_1x$  наилучшего среднеквадратичного приближения. Его график изображен на рис. 11.11, а.

Запишем теперь нормальную систему для многочлена второй степени:

$$\begin{aligned} 10a_0 + 4.5a_1 + 2.85a_2 &= 4.25, \\ 4.5a_0 + 2.85a_1 + 2.025a_2 &= 2.356, \\ 2.85a_0 + 2.025a_1 + 1.5333a_2 &= 1.6154, \end{aligned}$$

Решив ее, получим значения  $a_0 \approx 0.194$ ,  $a_1 \approx 0.452$ ,  $a_2 \approx 0.0947$  коэффициентов многочлена  $P_2(x) = a_0 + a_1x + a_2x^2$  наилучшего среднеквадратичного приближения.

Вычисления по формуле

$$\delta_m = \sqrt{\frac{1}{10} \sum_{i=0}^9 (P_m(x_i) - y_i)^2}$$

для  $m = 1$  и  $m = 2$  дают значения  $\delta_1 \approx 0.0486$ ,  $\delta_2 \approx 0.0481$ .

Так как средняя погрешность  $\epsilon$  исходных данных заведомо превышает 0.01, нетрудно заключить, что приближения многочленами первой и второй степени дают в данной ситуации практически эквивалентный результат. Учитывая большую простоту использования линейных функций, достаточно, по-видимому, остановиться на приближении  $f(x) \approx 0.183 + 0.538x$ .

**3. Некоторые вычислительные аспекты задачи наименьших квадратов.** Метод вычисления параметров  $a_0, a_1, \dots, a_m$  с помощью решения нормальной системы (11.101) кажется весьма привлекательным. Действительно, задача сводится к стандартной проблеме линейной алгебры — решению системы линейных алгебраических уравнений с квадратной матрицей. Более того, можно показать, что в случае, когда функции  $\varphi_0, \varphi_1, \dots, \varphi_m$  линейно независимы в точках  $x_0, x_1, \dots, x_n$ , матрица системы  $\Gamma$  является симметричной и положительно определенной. В частности, это означает, что при решении нормальной системы методом Гаусса не нужен выбор главных элементов; возможно также использование метода Холецкого (см. гл. 5).

Следует тем не менее обратить серьезное внимание на то обстоятельство, что при отсутствии специального выбора базисных функций  $\varphi_0, \varphi_1, \dots, \varphi_m$  уже при  $m \gtrsim 5$  нормальная система обычно оказывается очень плохо обусловленной. Казалось бы, из теоремы 11.11 следует, что единственное ограничение на систему базисных функций состоит в том, что она должна быть линейно независима в заданных точках. Однако, будучи формально линейно независимой, система функций  $\varphi_0,$

$\varphi_1, \dots, \varphi_m$  может оказаться очень близкой к линейно зависимой. Использование такой "почти линейно зависимой" системы базисных функций делает задачу метода наименьших квадратов плохо обусловленной. При переходе от задачи наименьших квадратов к задаче решения нормальной системы  $P^T P a = P^T y$  происходит как бы симметризация системы  $P a \approx y$  (см. § 6.3). При этом еще более ухудшается обусловленность задачи. В этом случае вычисленные на ЭВМ как решение системы (11.101) параметры модели могут оказаться полностью искаженными ошибками округления.

Простейший пример такой "почти линейно зависимой" системы базисных функций при больших  $m$  дает система  $1, x, \dots, x^m$ , широко применяемая при аппроксимации алгебраическими многочленами. При  $m \gtrsim 5$  соответствующая нормальная система, как правило, здесь настолько плохо обусловлена, что ее использование практически бесполезно.

В определенном смысле "наиболее линейно независимой" является система функций  $\varphi_0, \varphi_1, \dots, \varphi_m$ , ортогональных на множестве точек  $x_0, x_1, \dots, x_n$ . Матрица Грама такой системы диагональна, а потому решение нормальной системы (11.101) вычисляется легко:

$$a_k = b_k / \gamma_{kk}, \quad b_k = \sum_{i=0}^n y_i \varphi_k(x_i), \quad \gamma_{kk} = \sum_{i=0}^n \varphi_k(x_i)^2, \quad k = 0, 1, \dots, m.$$

Хотя выбор ортогональной на множестве точек  $x_0, x_1, \dots, x_n$  системы функций и желателен, он далеко не всегда возможен и удобен. Поэтому часто используются системы базисных функций, для которых матрица Грама лишь близка к диагональной. При аппроксимации на отрезке  $[-1, 1]$  алгебраическими многочленами степени  $m$  пример такой системы дает система многочленов Чебышева  $T_0(x), T_1(x), \dots, T_m(x)$ . Заметим, кстати, что найденный методом наименьших квадратов многочлен  $\tilde{P}_n(x) = \tilde{a}_0 T_0(x) + \tilde{a}_1 T_1(x) + \dots + \tilde{a}_m T_m(x)$  дает лишь иное, отличное от стандартного (11.95) представление многочлена наилучшего среднеквадратичного приближения. Однако задача определения параметров  $\tilde{a}_0, \tilde{a}_1, \dots, \tilde{a}_m$  обладает существенно лучшей обусловленностью и поэтому предпочтительнее с вычислительной точки зрения.

Существуют методы решения задачи наименьших квадратов, предваряющие решение нормальной системы численной ортогонализацией системы базисных функций (см., например, [50], [60]). Однако в настоящее время в серьезной вычислительной практике нормальная система, как правило, не используется. Применяются другие, более надежные методы (учитывающие, например, информацию об уровне

погрешности данных и относительной точности используемой ЭВМ). С одним из таких методов, основанном на сингулярном разложении матрицы  $P$ , можно познакомиться в [86].

**4. Понятие о статистических свойствах метода наименьших квадратов.** Пусть значения  $y_i$  функции  $f$  в точках  $x_i$  определяются в результате эксперимента. Предположим, что ошибки наблюдения  $\varepsilon_i = y_i^0 - y_i$  являются независимыми случайными величинами с нулевым средним значением и дисперсией, равной  $\sigma^2$ , т. е.

$$M[\varepsilon_i] = 0, \quad M[\varepsilon_i^2] = \sigma^2 \quad (i = 0, 1, \dots, n), \quad (11.105)$$

$$M[\varepsilon_i \varepsilon_j] = 0 \quad (i \neq j, \quad i = 0, 1, \dots, n, \quad j = 0, 1, \dots, n). \quad (11.106)$$

Рассмотрим сначала простейший случай, когда измеряемая величина постоянна, т. е.  $f(x) = a$ . В этом случае естественно искать приближение в виде постоянной  $a_0$ . В изложенной выше схеме это соответствует выбору  $m = 0$ ,  $\varphi_0(x) = 1$  и  $\Phi_0(x) = a_0$ , а нормальная система превращается в одно линейное уравнение  $(n + 1)a_0 = \sum_{i=0}^n y_i$ . Таким образом, оценкой постоянной величины  $a$  по методу наименьших квадратов является среднее арифметическое значение

$$a_0 = \frac{1}{n + 1} \sum_{i=0}^n y_i, \quad (11.107)$$

т. е. измеренные значения осредняются так, как это принято в статистике.

Пусть  $\Delta a_0 = a - a_0$  — ошибка оценки (11.107). Заметим, что  $\Delta a_0 = \frac{1}{n + 1} \sum_{i=0}^n \varepsilon_i$ , а потому

$$\begin{aligned} M[\Delta a_0] &= \frac{1}{n + 1} \sum_{i=0}^n M[\varepsilon_i] = 0, \\ D[\Delta a_0] &= \frac{1}{(n + 1)^2} \sum_{i=0}^n \sum_{j=0}^n M[\varepsilon_i \varepsilon_j] = \frac{\sigma^2}{n + 1}. \end{aligned} \quad (11.108)$$

Итак, математическое ожидание ошибки  $\Delta a_0$  равно нулю, причем, как видно из равенства (11.108), ее дисперсия стремится к нулю при  $n \rightarrow \infty$ . Аналогично усредняются случайные ошибки с ростом числа наблюдений и в общем случае.

Пусть  $\Phi_m^0(x) = \sum_{k=0}^m a_k^0 \varphi_k(x)$ ,  $\Phi_m^y(x) = \sum_{k=0}^m a_k \varphi_k(x)$  — многочлены наилучшего среднеквадратичного приближения, первый из которых отвечает

вектору  $\mathbf{y}^0 = (y_0^0, y_1^0, \dots, y_n^0)^T$  данных, не содержащих ошибок, а второй вектору  $\mathbf{y} = (y_0, y_1, \dots, y_n)^T$  данных, содержащих случайные ошибки.

Положим  $\mathbf{a}^0 = (a_0^0, a_1^0, \dots, a_m^0)^T$ ,  $\Delta \mathbf{a} = (\Delta a_0, \Delta a_1, \dots, \Delta a_m)^T$  (где  $\Delta a_k = a_k^0 - a_k$ ,  $k = 0, 1, \dots, m$ ) и  $\boldsymbol{\varepsilon} = (\varepsilon_0, \varepsilon_1, \dots, \varepsilon_n)^T$ . Рассмотрим многочлен

$$\Delta \Phi_m(x) = \Phi_m^{\mathbf{y}^0}(x) - \Phi_m^{\mathbf{y}}(x) = \sum_{k=0}^m \Delta a_k \varphi_k(x).$$

Так как векторы  $\mathbf{a}$  и  $\mathbf{a}^0$  удовлетворяют системам уравнений  $\Gamma \mathbf{a} = P^T \mathbf{y}$ ,  $\Gamma \mathbf{a}^0 = P^T \mathbf{y}^0$ , то вектор  $\Delta \mathbf{a}$  является решением системы

$$\Gamma \Delta \mathbf{a} = P^T \boldsymbol{\varepsilon}. \quad (11.109)$$

Отсюда вытекает равенство

$$\Delta \mathbf{a} = \Gamma^{-1} P^T \boldsymbol{\varepsilon}. \quad (11.110)$$

Заметим, что  $\Delta \Phi_m(x)$  и  $\Delta a_k$  — это случайные ошибки значения многочлена  $\Phi_m^{\mathbf{y}}(x)$  и его коэффициентов  $a_k$ , вызванные наличием случайных ошибок  $\varepsilon_i$  в исходных данных. Покажем, что эти ошибки имеют нулевое математическое ожидание.

Действительно, из формулы (11.110) следует, что

$$M[\Delta \mathbf{a}] = \Gamma^{-1} P^T M[\boldsymbol{\varepsilon}] = 0,$$

откуда в свою очередь имеем

$$M[\Delta \Phi_m(x)] = \sum_{k=0}^m M[\Delta a_k] \varphi_k(x) = 0.$$

Введем величину

$$\rho = \sqrt{\frac{1}{n+1} \sum_{i=0}^n (\Delta \Phi_m(x_i))^2},$$

равную среднеквадратичному значению ошибки  $\Delta \Phi_m(x)$ .

**Теорема 11.12.** *Справедливо равенство*

$$M[\rho^2] = \frac{m+1}{n+1} \sigma^2. \quad (11.111)$$

□ Заметим, что

$$\rho^2 = \frac{1}{n+1} (P \Delta \mathbf{a}, P \Delta \mathbf{a}) = \frac{1}{n+1} (\Delta \mathbf{a}, P^T P \Delta \mathbf{a}) =$$

$$= \frac{1}{n+1} (\Gamma^{-1} P^T \epsilon, P^T \epsilon) = \frac{1}{n+1} (P \Gamma^{-1} P^T \epsilon, \epsilon).$$

Из определения операции умножения матриц следует, что элемент  $a_{ij}$  матрицы  $A = P \Gamma^{-1} P^T$  имеет вид  $a_{ij} = \sum_{l=0}^m \sum_{k=0}^m p_{il} \gamma_{lk}^{(-1)} p_{kj}^T$ , где  $\gamma_{lk}^{(-1)}$  — элементы матрицы  $\Gamma^{-1}$ ,  $p_{kj}^T$  — элементы матрицы  $P^T$ . Поэтому

$$\begin{aligned} M[\rho^2] &= \frac{1}{n+1} \sum_{i=0}^n \sum_{j=0}^n a_{ij} M[\epsilon_i \epsilon_j] = \frac{1}{n+1} \sum_{i=0}^n a_{ii} \sigma^2 = \\ &= \frac{1}{n+1} \sum_{l=0}^m \sum_{k=0}^m \left( \sum_{i=0}^n p_{ki}^T p_{il} \right) \gamma_{lk}^{(-1)} \sigma^2 = \frac{1}{n+1} \sum_{l=0}^m \sum_{k=0}^m \gamma_{kl} \gamma_{lk}^{(-1)} \sigma^2 = \frac{m+1}{n+1} \sigma^2. \end{aligned}$$

Здесь  $\gamma_{kl} = \sum_{i=0}^n p_{ki}^T p_{il}$  — элементы матрицы  $\Gamma$ . ■

**З а м е ч а н и е 1.** Величина  $M[\rho^2]$  представляет собой среднее по точкам  $x_i$  значение дисперсии случайной ошибки  $\Delta \Phi_m(x_i)$ . Из теоремы 11.12 следует, что  $M[\rho^2] \rightarrow 0$  при  $n \rightarrow \infty$ , т. е. при неограниченном росте числа наблюдений среднее значение дисперсии ошибки стремится к нулю.

**З а м е ч а н и е 2.** Равенство (11.111) подтверждает представление о том, что статистические свойства метода наименьших квадратов проявляются при  $n \gg m$ , т. е. тогда, когда число наблюдений много больше числа параметров модели.

Введем обозначения  $\delta_m = \delta(\Phi_m^y, y)$ ,  $\delta_m^0 = \delta(\Phi_m^y, y^0)$ ,  $d_m = \delta(\Phi_m^y, y^0)$ . Заметим, что величина  $d_m$  представляет собой среднеквадратичное отклонение многочлена наилучшего среднеквадратичного приближения  $\Phi_m^y$  (построенного по вектору  $y$  исходных данных, содержащих случайные ошибки) от вектора  $y^0$  точных значений функции  $f$ , которую мы и пытаемся оценить. Именно эту величину следует считать "истинной" мерой погрешности. Вычислим математические ожидания величин  $\delta_m^2$  и  $d_m^2$ .

**Т е о р е м а 11.13.** *Справедливы равенства*

$$M[d_m^2] = (\delta_m^0)^2 + \frac{m+1}{n+1} \sigma^2, \quad (11.112)$$

$$M[\delta_m^2] = (\delta_m^0)^2 + \frac{n-m}{n+1} \sigma^2. \quad (11.113)$$

□ В силу леммы 11.1 имеет место равенство

$$s(\mathbf{a}, \mathbf{y}^0) = s(\mathbf{a}^0, \mathbf{y}^0) + |P\Delta \mathbf{a}|^2,$$

которое в принятых выше обозначениях примет вид  $d_m^2 = (\delta_m^0)^2 + \rho^2$ . Вычислив математическое ожидание и используя теорему 11.12, получим равенство (11.112).

Заметим теперь, что в силу леммы 11.1  $s(\mathbf{a}^0, \mathbf{y}) = s(\mathbf{a}, \mathbf{y}) + |P\Delta \mathbf{a}|^2$ . Преобразуем левую часть этого равенства:

$$s(\mathbf{a}^0, \mathbf{y}) = |(P\mathbf{a}^0 - \mathbf{y}^0) + \varepsilon|^2 = |P\mathbf{a}^0 - \mathbf{y}^0|^2 + 2(P\mathbf{a}^0 - \mathbf{y}^0, \varepsilon) + |\varepsilon|^2.$$

Таким образом,

$$\delta_m^2 = \frac{1}{n+1} s(\mathbf{a}, \mathbf{y}) = (\delta_m^0)^2 + \frac{1}{n+1} |\varepsilon|^2 - \rho^2 + \frac{2}{n+1} (P\mathbf{a}^0 - \mathbf{y}^0, \varepsilon).$$

Учитывая, что

$$M[|\varepsilon|^2] = \sum_{i=0}^n M[\varepsilon_i^2] = (n+1) \sigma^2, \quad M[\rho^2] = \frac{m+1}{n+1} \sigma^2, \\ M[(P\mathbf{a}^0 - \mathbf{y}^0, \varepsilon)] = (P\mathbf{a}^0 - \mathbf{y}^0, M[\varepsilon]) = 0,$$

получим равенство (11.113). ■

**5. О выборе степени обобщенного многочлена.** Пусть функцию  $f$  можно аппроксимировать с достаточно высокой точностью  $\varepsilon$  обобщенным многочленом  $\Phi_m(x) = \sum_{k=0}^m a_k \varphi_k(x)$  некоторой степени  $m$ . Если эта степень заранее не известна, то возникает проблема выбора оптимальной степени аппроксимирующего многочлена  $\Phi_m^y$  в условиях, когда исходные данные  $y_i$  содержат случайные ошибки  $\varepsilon_i$ .

Пусть  $\varphi_0, \varphi_1, \dots, \varphi_m$  — фиксированный набор базисных функций, линейно независимых в точках  $x_0, x_1, \dots, x_n$ . Предположим, что  $n \gg m$ , а ошибки  $\varepsilon_i$  удовлетворяют условиям (11.105), (11.106). Будем решать задачу наименьших квадратов для  $m = 0, 1, 2, \dots$ , постепенно увеличивая число параметров модели. Отметим, что значения среднеквадратичных уклонений  $\delta_m$  и  $\delta_m^0$  должны с ростом  $m$  убывать. Действительно, множество всех многочленов  $\Phi_{m+1}$  степени  $m+1$  включает в себя множество всех многочленов степени  $\Phi_m$  и поэтому

$$\delta_{m+1} = \min_{\Phi_{m+1}} \delta(\Phi_{m+1}, \mathbf{y}) \leq \min_{\Phi_m} \delta(\Phi_m, \mathbf{y}) = \delta_m, \quad m \geq 0,$$

$$\delta_{m+1}^0 = \min_{\Phi_{m+1}} \delta(\Phi_{m+1}, \mathbf{y}^0) \leq \min_{\Phi_m} \delta(\Phi_m, \mathbf{y}^0) = \delta_m^0, \quad m \geq 0.$$

Заметим также, что в силу теоремы 11.13 и закона больших чисел (при  $n > 1$ ) справедливы следующие приближенные равенства:

$$\delta_m^2 = \delta(\Phi_m^y, y)^2 \approx (\delta_m^0)^2 + \frac{n-m}{n+1} \sigma^2, \quad (11.114)$$

$$d_m^2 = \delta(\Phi_m^y, y^0)^2 \approx (\delta_m^0)^2 + \frac{m+1}{n+1} \sigma^2. \quad (11.115)$$

Как нетрудно видеть, с ростом  $m$  первое слагаемое в правой части равенства (11.115) убывает, а второе возрастает. Поэтому следует ожидать, что величина  $d_m$  (именно она и характеризует уклонение вычисляемого многочлена  $\Phi_m^y$  от функции  $f$ ) с ростом  $m$  должна сначала убывать, а затем, достигнув своего минимума при некотором  $m = m_0$ , начать возрастать.

Итак, существует оптимальная (в смысле критерия  $d_m$ ) степень аппроксимации  $m_0$ . Однако несмотря на то, что увеличивая  $m$ , можно получать все лучшее соответствие многочлена  $\Phi_m^y$  с экспериментальными данными, следует иметь в виду, что начиная с  $m = m_0$ , многочлен будет все хуже соответствовать приближаемой функции.

Выбор оптимальной степени  $m_0$  не представлял бы труда, если бы значения  $d_m$  можно было вычислять. Однако в действительности прямому вычислению поддаются только значения среднеквадратичного уклонения  $\delta_m$ , анализируя которые мы и должны выбрать степень многочлена.

Предположим, что дисперсия  $\sigma^2$  (или ее оценка) случайных ошибок  $\varepsilon_i$  известна. Пусть также известно, что для некоторого значения  $m < n$  возможно приближение, для которого  $\delta_m^0 < \sigma$ . Тогда, начиная с этого значения  $m$ , согласно формуле (11.114) с учетом того, что  $\frac{n-m}{n+1} \approx 1$ , будет иметь место приближенное равенство

$$\delta_m \approx \sigma. \quad (11.116)$$

Таким образом, за оптимальное значение степени многочлена следует принять то значение  $m$ , при котором впервые будет выполнено приближенное равенство (11.116). При имеющейся информации лучший выбор вряд ли возможен.

Пусть теперь значение  $\sigma^2$  дисперсии ошибок  $\varepsilon_i$  нам не известно. Зато известно, что функция  $f$  либо представляет собой обобщенный многочлен  $\Phi_m$  некоторой степени  $m_0$  (и тогда  $\delta_m^0 = c_0 = 0$  для всех

$m \geq m_0$ ), либо же, начиная с некоторого  $m = m_0$ , увеличение степени многочлена в широком диапазоне значений  $m_0 \leq m \leq m_1$  практически не влияет на качество приближения (т. е.  $\delta_m^0 \approx c_0 = \text{const}$  для всех  $m_0 \leq m \leq m_1$ ). Согласно формуле (11.114) справедливо приближенное равенство

$$\sigma_m^2 \equiv \frac{n+1}{n-m} \delta_m^2 \approx \frac{n+1}{n-m} (\delta_m^0)^2 + \sigma^2. \quad (11.117)$$

При  $m \geq m_0$  величина, стоящая в правой части этого равенства, приближенно равна  $\frac{n+1}{n-m} c_0^2 + \sigma^2$  и не убывает по  $m$ . Это наблюдение позволяет использовать в рассматриваемой ситуации следующее практическое правило выбора: за оптимальное значение степени многочлена следует принять то значение  $m$ , начиная с которого величина  $\sigma_m^2$  стабилизируется или начинает возрастать.

**Пример 11.16.** Найдем оптимальную степень алгебраического многочлена для аппроксимации функции, заданной табл. 11.13.

Заметим, что фактически оптимальная степень  $m = 1$  уже была найдена при решении примера 11.15. Основанием для такого вывода послужило сравнение среднеквадратичных отклонений  $\delta_1 \approx 0.0486$  и  $\delta_2 \approx 0.0481$  с оценкой уровня "шума" таблицы — грубый аналог критерия (11.116).

Попробуем получить тот же вывод, используя значения величин (11.117). Найдем дополнительно  $P_0(x) = 0.425$  и  $\delta_0 \approx 0.162$ . Тогда  $\sigma_0^2 = \frac{10}{9} \delta_0^2 \approx 0.292$ ,  $\sigma_1^2 = \frac{10}{8} \delta_1^2 \approx 0.00295$ ,  $\sigma_2^2 = \frac{10}{7} \delta_2^2 \approx 0.00381$ . Так как  $\sigma_0^2 > \sigma_1^2$  и  $\sigma_1^2 < \sigma_2^2$ , то за оптимальное значение степени следует принять  $m = 1$ .

**6. Нелинейная задача наименьших квадратов.** Часто из физических или каких-либо других соображений следует, что зависимость  $y = f(x)$  между величинами  $y$  и  $x$  должна хорошо описываться моделью вида  $y = g(x, a)$ , где функция  $g(x, a) = g(x, a_0, a_1, \dots, a_m)$  нелинейно зависит от параметров  $a_0, a_1, \dots, a_m$ .

Пусть функция  $y = f(x)$  задана таблицей значений  $y_i = f(x_i)$ ,  $i = 0, 1, \dots, n$ , где  $n \gg m$ . Тогда применение критерия наименьших квадратов приводит к задаче определения искомых параметров  $a_0, a_1, \dots, a_m$  из условия минимума функции

$$s(a, y) = \sum_{i=0}^n (g(x_i, a) - y_i)^2.$$



Нелинейная задача наименьших квадратов (особенно при большом числе параметров) весьма трудна для решения. Обычно для вычисления параметров  $a$  применяются специальные методы минимизации [32].

В некоторых весьма специальных случаях решение нелинейной задачи наименьших квадратов можно свести к решению линейной задачи. Пусть, например, зависимость  $y$  от  $x$  ищется в виде  $y = ae^{bx}$ , где  $a > 0$ . Логарифмируя это равенство, приходим к линейной зависимости  $\ln y = \ln a + bx$  величины  $Y = \ln y$  от  $x$ . Теперь по таблице значений  $Y_i = \ln y_i$  ( $i = 0, 1, \dots, n$ ) можно легко определить значения  $\ln a$  и  $b$ . Подчеркнем все же, что найденные таким образом значения параметров  $a$  и  $b$  отличаются от тех значений, которые могут быть найдены непосредственной минимизацией функции  $\sum_{i=0}^n (ae^{bx_i} - y_i)^2$ .

#### § 11.14. Равномерное приближение функций

**1. Задача о наилучшем равномерном приближении.** Пусть  $f(x)$  — заданная на отрезке  $[a, b]$  непрерывная функция. Будем говорить, что многочлен  $P_n(x)$  приближает функцию  $f$  равномерно на отрезке  $[a, b]$  с точностью  $\epsilon$ , если  $\Delta(P_n) = \max_{[a, b]} |f(x) - P_n(x)| \leq \epsilon$ . Таким образом,

величина  $\Delta(P_n)$  играет здесь роль погрешности приближения.

Естественно поставить следующую задачу: среди всех многочленов фиксированной степени  $n$  найти многочлен  $Q_n(x)$ , для которого величина погрешности равномерного приближения минимальна, т. е.  $\Delta(Q_n) \leq \Delta(P_n)$  для любого многочлена  $P_n(x)$  степени  $n$ . Поставленная задача называется *задачей о наилучшем равномерном приближении*, а искомый многочлен  $Q_n(x)$  — *многочленом наилучшего равномерного приближения*. Справедливо следующее утверждение.

**Теорема 11.14.** Для любой непрерывной на отрезке  $[a, b]$  функции  $f$  многочлен наилучшего равномерного приближения  $Q_n$  степени  $n$  существует и единствен.

**Пример 11.17.** Покажем, что многочленом наилучшего равномерного приближения нулевой степени для функции  $y = \sqrt{x}$  на отрезке  $[0, 1]$  является  $Q_0(x) = 1/2$ . Заметим, что  $\Delta(Q_0) = \max_{[0, 1]} |\sqrt{x} - 1/2| = 1/2$  (рис. 11.12, а) и

этот максимум достигается в точках  $x_0 = 0$  и  $x_1 = 1$ . Для любого другого многочлена  $P_0(x) = a$ , где  $a \neq 1/2$ , значение  $\Delta(P_0) > 1/2$ . В самом деле, если

$a > 1/2$ , то  $\Delta(P_0) \geq |\sqrt{x_0} - a| = a > 1/2$ . Если же  $a < 1/2$ , то  $\Delta(P_0) \geq |\sqrt{x_1} - a| = 1 - a > 1/2$ .

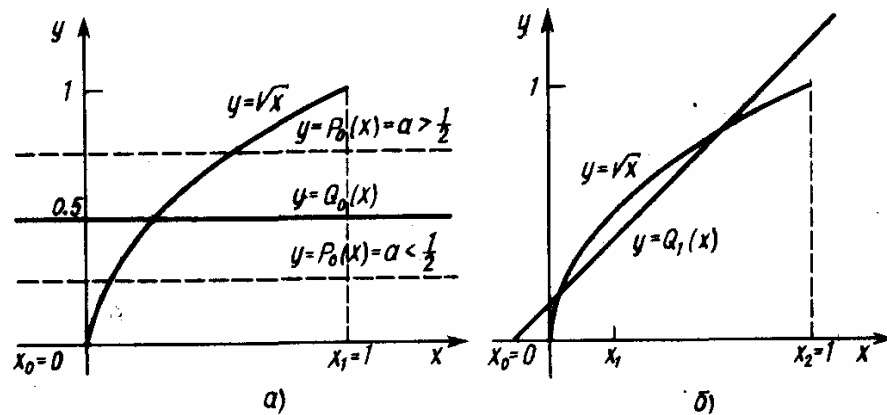


Рис. 11.12

Приведем без доказательства один из наиболее известных результатов о многочленах наилучшего равномерного приближения.

**Т е о р е м а 11.15 (теорема Чебышева).** Для того чтобы многочлен  $Q_n(x)$  был многочленом наилучшего равномерного приближения непрерывной на отрезке  $[a, b]$  функции  $f(x)$ , необходимо и достаточно, чтобы на отрезке  $[a, b]$  нашлись по крайней мере  $n + 2$  точки  $x_0 < x_1 < x_2 < \dots < x_{n+1}$  такие, что

$$f(x_i) - Q_n(x_i) = \alpha(-1)^i \max_{[a, b]} |f(x) - Q_n(x)|, \quad i = 0, 1, \dots, n + 1. \quad (11.118)$$

Здесь  $\alpha$  — постоянная, равная 1 или  $-1$  для всех  $i$  одновременно.

Точки  $x_0, x_1, \dots, x_{n+1}$ , удовлетворяющие условиям теоремы, принято называть *точками чебышевского альтернанса*<sup>1</sup>. Равенство (11.118) накладывает на точки чебышевского альтернанса два требования:

1) в точках  $x_i$  модуль погрешности приближения функции  $f$  многочленом  $Q_n$  достигает максимума:  $|f(x_i) - Q_n(x_i)| = \max_{[a, b]} |f(x) - Q_n(x)|$ ;

2) для всех  $i = 0, 1, \dots, n$  погрешность  $f(x_i) - Q_n(x_i)$  меняет знак при переходе от точки  $x_i$  к следующей точке  $x_{i+1}$ .

<sup>1</sup> От лат. alternare — "чередоваться".

**Пример 11.18.** В примере 11.17 точками чебышевского альтернанса являются точки  $x_0 = 0$  и  $x_1 = 1$  (число точек равно двум, так как  $n = 0$ ). В самом деле, в этих точках достигается максимум модуля погрешности, а сама погрешность меняет знак при переходе от  $x_0$  к  $x_1$ .

**Пример 11.19.** Найдем многочлен наилучшего равномерного приближения первой степени для функции  $y = \sqrt{x}$  на отрезке  $[0, 1]$ .

В рассматриваемом случае  $n = 1$  и должны быть по крайней мере три точки чебышевского альтернанса. В частности, это означает, что графики функций  $y = \sqrt{x}$  и  $y = Q_1(x) = ax + b$  должны пересекаться хотя бы дважды (рис. 11.12, б). Функция  $\varphi(x) = \sqrt{x} - Q_1(x)$  вогнута и потому может иметь на отрезке  $[0, 1]$  лишь одну внутреннюю точку экстремума  $x_1$ . Следовательно, две из точек чебышевского альтернанса совпадают с концами отрезка:  $x_0 = 0$ ,  $x_2 = 1$ . В точке  $x_1$  функция  $\varphi(x)$  удовлетворяет необходимому условию экстремума  $\varphi'(x_1) = 0$ , что эквивалентно уравнению

$$\frac{1}{2\sqrt{x_1}} - a = 0. \quad (11.119)$$

С учетом равенств  $\varphi(x_0) = -b$ ,  $\varphi(x_1) = \sqrt{x_1} - ax_1 - b$ ,  $\varphi(x_2) = 1 - a - b$  условие перемены знака  $\varphi(x_0) = -\varphi(x_1) = \varphi(x_2)$  эквивалентно двум уравнениям

$$-b = -\sqrt{x_1} + ax_1 + b, \quad (11.120)$$

$$-b = 1 - a - b. \quad (11.121)$$

Из уравнения (11.121) сразу находим, что  $a = 1$ . Затем из уравнения (11.119) определяем, что  $x_1 = 0.25$ . Наконец, из (11.120) получаем  $b = 1/8$ .

Таким образом,  $Q_1(x) = x + 1/8$  — многочлен наилучшего равномерного приближения первой степени, аппроксимирующий функцию  $\sqrt{x}$  с погрешностью  $\Delta(Q_1) = 1/8$ .

**2. Задача о понижении степени многочлена.** Пусть  $P_m(x) = a_m x^m + a_{m-1} x^{m-1} + \dots + a_0$  — многочлен степени  $m \geq 1$ , значения которого вычисляются на стандартном отрезке  $[-1, 1]$  (напомним, что к стандартному отрезку можно перейти от произвольного отрезка  $[a, b]$  линейной заменой переменных). Поставим следующую задачу о понижении степени многочлена: аппроксимировать  $P_m(x)$  на отрезке  $[-1, 1]$  многочленом  $Q_{m-1}(x)$  наилучшего равномерного приближения на единицу меньшей степени.

Заметим, что  $R_m(x) = P_m(x) - Q_{m-1}(x)$  — многочлен степени  $m$  со старшим коэффициентом, равным старшему коэффициенту  $a_m$  многочлена  $P_m(x)$ . Поставленную задачу можно иначе сформулировать так: среди всех многочленов степени  $m$  с фиксированным старшим коэф-

коэффициентом  $a_m$  найти многочлен  $R_m$ , для которого величина  $\max |R_m(x)|$  минимальна. Как известно (см. § 11.6), решение этой задачи

дает многочлен  $R_m(x) = \frac{a_m}{2^{m-1}} T_m(x)$  и для него  $\max_{[-1, 1]} |R_m(x)| = \frac{|a_m|}{2^{m-1}}$ . Таким образом, решением поставленной задачи является многочлен

$$Q_{m-1}(x) = P_m(x) - \frac{a_m}{2^{m-1}} T_m(x). \quad (11.122)$$

Соответствующая погрешность приближения равна  $\frac{|a_m|}{2^{m-1}}$ .

**З а м е ч а н и е.** Тривиальный способ понижения степени многочлена  $P_m(x)$  — отбрасывание старшего слагаемого  $a_m x^m$  дает погрешность, равную  $|a_m|$ , т. е. в  $2^{m-1}$  раз большую, чем приближение многочленом (11.122).

**3. Нахождение многочленов, близких к наилучшим.** В большинстве реальных случаев задача о наилучшем равномерном приближении непрерывной функции  $f$  является очень трудной. Для ее решения развиты специальные численные методы, реализованные в виде стандартных программ. Заметим, однако, что во многих ситуациях достаточно ограничиться нахождением многочлена, близкого к наилучшему, либо просто найти многочлен, равномерно приближающий функцию  $f$  с заданной точностью  $\varepsilon$ . Укажем на два случая, когда возможно нахождение многочленов, близких к наилучшим.

1°. Пусть производная  $f^{(n+1)}(x)$  функции  $f$  слабо меняется на отрезке  $[a, b]$ . Тогда интерполяционный многочлен  $P_n(x)$  с чебышевскими узлами (11.43) близок к многочлену наилучшего равномерного приближения.

2°. Пусть функция  $f(x)$  задана на отрезке  $[-1, 1]$  равномерно сходящимся степенным рядом (рядом Тейлора):

$$f(x) = \sum_{k=0}^{\infty} a_k x^k. \quad (11.123)$$

Требуется найти многочлен минимальной степени, равномерно приближающий функцию  $f$  на отрезке  $[-1, 1]$  с заданной точностью  $\varepsilon$ .

Излагаемый ниже метод решения этой задачи часто называют *экономизацией степенных рядов*. Сначала берут отрезок ряда Тейлора

$$P_m(x) = \sum_{k=0}^m a_k x^k, \text{ аппроксимирующий функцию } f \text{ с точностью } \varepsilon_0 < \varepsilon.$$

Далее степень многочлена последовательно понижают. Если погреш-

ность  $\varepsilon_1 = \frac{|a_m|}{2^{m-1}}$  понижения степени такова, что  $\varepsilon_0 + \varepsilon_1 \leq \varepsilon$ , то многочлен  $P_m$  заменяют многочленом  $P_{m-1} = P_m - \frac{a_m}{2^{m-1}} T_m = \sum_{k=0}^{m-1} a_k^{(1)} x^k$ . Если погрешность  $\varepsilon_2 = \frac{|a_{m-1}^{(1)}|}{2^{m-2}}$  такова, что  $\varepsilon_0 + \varepsilon_1 + \varepsilon_2 \leq \varepsilon$ , то снова понижают степень многочлена  $P_{m-1}$  по формуле  $P_{m-2} = P_{m-1} - \frac{a_{m-1}^{(1)}}{2^{m-2}} T_{m-1}$  и т. д. Процесс прерывают тогда, когда вычисление очередного  $\varepsilon_k$  дает  $\varepsilon_0 + \varepsilon_1 + \dots + \varepsilon_k > \varepsilon$ . В этом случае полагают  $f(x) \approx P_{m-k+1}(x)$ .

**Пример 11.20.** Найдем многочлен минимальной степени, аппроксимирующий функцию  $y = \sin x$  на отрезке  $[-1, 1]$  с точностью  $\varepsilon = 10^{-3}$ .

Ряд  $\sin x = \sum_{k=0}^{\infty} (-1)^k \frac{x^{2k+1}}{(2k+1)!}$  — знакопеременный, а его слагаемые убывают по модулю. Поэтому погрешность приближения функции  $\sin x$  отрезком ряда Тейлора  $P_{2n+1}(x) = \sum_{k=0}^n (-1)^k \frac{x^{2k+1}}{(2k+1)!}$  оценивается величиной  $\varepsilon_0 = \frac{1}{(2n+3)!}$ , равной максимуму модуля первого отброшенного слагаемого. Выбор  $n = 2$  дает значение  $\varepsilon_0 = \frac{1}{5040} \approx 2 \cdot 10^{-4} \leq \varepsilon$ . Следовательно, многочлен  $P_5(x) = x - \frac{x^3}{6} + \frac{x^5}{120}$  аппроксимирует функцию  $y = \sin x$  с точностью  $\varepsilon_0 \approx 2 \cdot 10^{-4}$ .

Понижение степени многочлена  $P_5$  будет сопровождаться дополнительной погрешностью  $\varepsilon_1 = \frac{|a_5|}{2^4} = \frac{1}{1920} \approx 5.2 \cdot 10^{-4}$ . Следовательно,  $\varepsilon_0 + \varepsilon_1 < \varepsilon$  и после понижения степени по формуле

$$P_5(x) - \frac{1}{1920} T_5(x) = x - \frac{x^3}{6} + \frac{x^5}{120} - \frac{1}{1920} (16x^5 - 20x^3 + 5x)$$

получим многочлен

$$P_3(x) = \frac{383}{384} x - \frac{5}{32} x^3, \quad (11.124)$$

дающий приближение к  $\sin x$  на отрезке  $[-1, 1]$  с точностью  $7.2 \cdot 10^{-4}$ .

Так как  $\varepsilon_3 = \frac{5}{32} \cdot \frac{1}{2^2} > 10^{-3}$ , то дальнейшее понижение степени невозможно и решением задачи является многочлен (11.124).

## § 11.15. Дробно-рациональные аппроксимации и вычисление элементарных функций

При создании стандартных программ вычисления элементарных и специальных функций специалистами по математическому обеспечению ЭВМ применяются разнообразные приемы, требующие глубоких профессиональных знаний. Используемые вычислительные методы не являются здесь машинно-независимыми, а, наоборот, существенно учитывают разрядность мантиссы, скорость выполнения арифметических операций и другие особенности конкретной ЭВМ. Отметим, что к указанным стандартным программам обычно предъявляется требование обеспечения относительной точности результата порядка машинного эпсилон  $\epsilon_m$ .

Использование богатой дополнительной информации об аналитических свойствах элементарных и специальных функций позволяет значительно уменьшить объем вычислений. Существенно используется возможность представления вычисляемых функций сходящимися степенными рядами вида

$$\sum_{k=0}^{\infty} c_k z^k. \quad (11.125)$$

Здесь  $z = x - x_0$ ;  $x_0$  — точка, в которой осуществляется разложение функции в ряд. Отметим, однако, что вопреки распространенному мнению такие ряды непосредственно практически никогда не используются для вычисления функций.

Широко применяемым в настоящее время способом представления функций является приближение их рациональными дробями вида

$$R(z) = \frac{a_0 + a_1 z + \dots + a_n z^n}{b_0 + b_1 z + \dots + b_m z^m}. \quad (11.126)$$

К дробно-рациональным аппроксимациям приходят различными путями. В ряде случаев используется *рациональная интерполяция* — интерполяция функции рациональной дробью (11.126). Тогда коэффициенты  $a_j$  ( $j = 0, 1, \dots, n$ ),  $b_k$  ( $k = 0, 1, \dots, m$ ) находятся из совокупности соотношений  $R(z_i) = y_i$  ( $0 \leq i < N$ ,  $N = n + m + 1$ ), которые можно записать в следующем виде:

$$\sum_{j=0}^n a_j x_i^j = y_i \sum_{k=0}^m b_k x_i^k.$$

Эти соотношения образуют систему  $N$  линейных алгебраических уравнений относительно  $N + 1$  неизвестных. Такие системы всегда имеют

нетривиальные решения. Можно записать  $R(z)$  и в явном виде, если использовать аппарат обратных разделенных разностей [9].

Один из возможных путей состоит в использовании теории *цепных* (или *непрерывных*) *дробей*. Например, функция  $\operatorname{tg} x$  представляется цепной дробью

$$\operatorname{tg} x = \frac{x}{1 - \frac{x^2}{3 - \frac{x^2}{5 - \dots}}}$$

Обрывая такую бесконечную дробь, получают некоторую конечную дробь, аппроксимирующую функцию.

Все более популярным в последние годы способом приближения аналитических функций становится *аппроксимация Паде* — такая дробно-рациональная аппроксимация (11.126), для которой

$$\sum_{k=0}^{\infty} c_k z^k = \frac{a_0 + a_1 z + \dots + a_n z^n}{b_0 + b_1 z + \dots + b_m z^m} + O(z^{n+m+1}). \quad (11.127)$$

Равенство (11.127) означает, что коэффициенты  $a_0, a_1, \dots, a_n, b_0, b_1, \dots, b_m$  дроби (11.126) подбираются так, чтобы в разложении ее в ряд Тейлора первые  $n + m + 1$  слагаемых в точности совпадали с соответствующими слагаемыми ряда (11.125).

В качестве примера приведем две аппроксимации Паде функции  $e^x$  в случаях  $n = 2, m = 2$  и  $n = 3, m = 3$ :

$$\begin{aligned} e^x &\approx \frac{12 + 6x + x^2}{12 - 6x + x^2}, \\ e^x &\approx \frac{12(x^2 + 10) + x(x^2 + 60)}{12(x^2 + 10) - x(x^2 + 60)}. \end{aligned} \quad (11.128)$$

Отметим, что при  $|x| \leq 0.5 \ln 2$  аппроксимация (11.128) обеспечивает точность  $9 \cdot 10^{-9}$ .

В заключение параграфа рассмотрим, как вычисляется в одной из стандартных программ функция  $y = \ln x$ . Аргумент  $x$  представляют в виде  $x = \mu \cdot 2^p$ , где  $p$  — двоичный порядок,  $\mu$  — мантисса,  $0.5 \leq \mu < 1$ . Затем используют разложение

$$\ln x = (p - 0.5) \ln 2 + 2v \sum_{k=0}^{\infty} \frac{1}{2k + 1} v^{2k}, \quad \text{где } v = \frac{\sqrt{2}\mu - 1}{\sqrt{2}\mu + 1}.$$

Заметим, что  $|v| \leq a = (\sqrt{2} - 1)/(\sqrt{2} + 1) < 0.172$ . Ряд  $\sum_{k=0}^{\infty} \frac{1}{2k + 1} v^{2k}$  заменяют затем на отрезке  $[-a, a]$  многочленом, близким к многочлену

четвертой степени наилучшего равномерного приближения. В результате получается формула

$$\ln x \approx (p - 0.5)\ln 2 + v (2.000000815 + 0.666445069v^2 + 0.415054254v^4),$$

погрешность которой для всех  $x$  не превышает  $3 \cdot 10^{-8}$ .

### § 11.16. Дополнительные замечания

1. Хотя в данном пособии интерполирование рассматривается довольно подробно, все же за пределами обсуждения оказывается ряд полезных приемов интерполирования и соответствующих приложений (таких, как, например, интерполяционный многочлен Бесселя и обратная интерполяция). Подробности можно найти в [9].

2. Тем, кто интересуется практическим применением сплайнов, рекомендуем книгу [16]. В ней можно найти не только изложение теории и алгоритмов решения задач, но и полезные практические советы и тексты соответствующих фортранных программ.

3. Изложение современных вычислительных методов решения линейных задач метода наименьших квадратов содержится в общепризнанном учебнике-справочнике [50]. Заметим, что в оригинальное издание этой книги включены и тексты соответствующих фортранных подпрограмм, которые были, к сожалению, опущены при переводе.

4. Исключительно богатый материал по специальным и элементарным функциям содержит справочник [1]. Эта книга пользуется заслуженной популярностью у специалистов, и тот, кто занимается вычислением специальных функций лишь эпизодически, может найти в ней ответы на большинство интересующих его вопросов. Правда, большая часть приведенных в справочнике результатов была получена до 1960 г. Как дополнение к [1] можно рассматривать книгу [51].

5. Желая более глубоко ознакомиться с аппроксимациями Паде и непрерывными (цепными) дробями рекомендуем обратиться к специальной литературе [11], [31].

6. Подчеркнем, что в данной главе рассматривались методы приближения функций только одной вещественной переменной. В случае аппроксимации функций многих переменных можно использовать аналогичные подходы (см., например, [9], [54]).



## Глава 12

### ЧИСЛЕННОЕ ДИФФЕРЕНЦИРОВАНИЕ

Численное дифференцирование применяется тогда, когда функцию трудно или невозможно продифференцировать аналитически. Например, необходимость в численном дифференцировании возникает в том случае, когда функция задана таблицей. Кроме того, формулы численного дифференцирования широко используются при разработке вычислительных методов решения многих задач (решение дифференциальных уравнений, поиск решений нелинейных уравнений, поиск точек экстремума функций и др.).

#### § 12.1. Простейшие формулы численного дифференцирования

1. **Вычисление первой производной.** Предположим, что в окрестности точки  $x$  функция  $f$  дифференцируема достаточное число раз. Исходя из определения производной

$$f'(x) = \lim_{\Delta x \rightarrow 0} \frac{f(x + \Delta x) - f(x)}{\Delta x},$$

естественно попытаться использовать для ее вычисления две простейшие приближенные формулы:

$$f'(x) \approx \frac{f(x + h) - f(x)}{h}, \quad (12.1)$$

$$f'(x) \approx \frac{f(x) - f(x - h)}{h}, \quad (12.2)$$

соответствующие выбору фиксированных значений  $\Delta x = h$  и  $\Delta x = -h$ . Здесь  $h > 0$  — малый параметр (*шаг*). Разностные отношения в правых

частях формул (12.1) и (12.2) часто называют *правой и левой разностными производными* [70].

Для оценки погрешностей

$$r_+(x, h) = f'(x) - \frac{f(x+h) - f(x)}{h},$$

$$r_-(x, h) = f'(x) - \frac{f(x) - f(x-h)}{h}$$

введенных формул численного дифференцирования (*погрешностей аппроксимации*) воспользуемся формулами Тейлора:

$$f(x \pm h) = f(x) \pm f'(x)h + \frac{f''(\xi_{\pm})}{2} h^2. \quad (12.3)$$

Здесь и ниже  $\xi_+$  и  $\xi_-$  — некоторые точки, расположенные на интервалах  $(x, x+h)$  и  $(x-h, x)$  соответственно. Подставляя разложения (12.3) в выражения для  $r_{\pm}$ , получаем  $r_+(x, h) = -\frac{1}{2} f''(\xi_+) h$ ,  $r_-(x, h) = \frac{1}{2} f''(\xi_-) h$ . Следовательно,

$$|r_+(x, h)| \leq \frac{1}{2} M_2 h, \quad M_2 = \max_{[x, x+h]} |f''(\xi)|, \quad (12.4)$$

$$|r_-(x, h)| \leq \frac{1}{2} M_2 h, \quad M_2 = \max_{[x-h, x]} |f''(\xi)|, \quad (12.5)$$

Таким образом, формулы (12.1), (12.2) имеют первый порядок точности по  $h$ . Иначе говоря, правая и левая разностные производные аппроксимируют производную  $f'(x)$  с первым порядком точности.

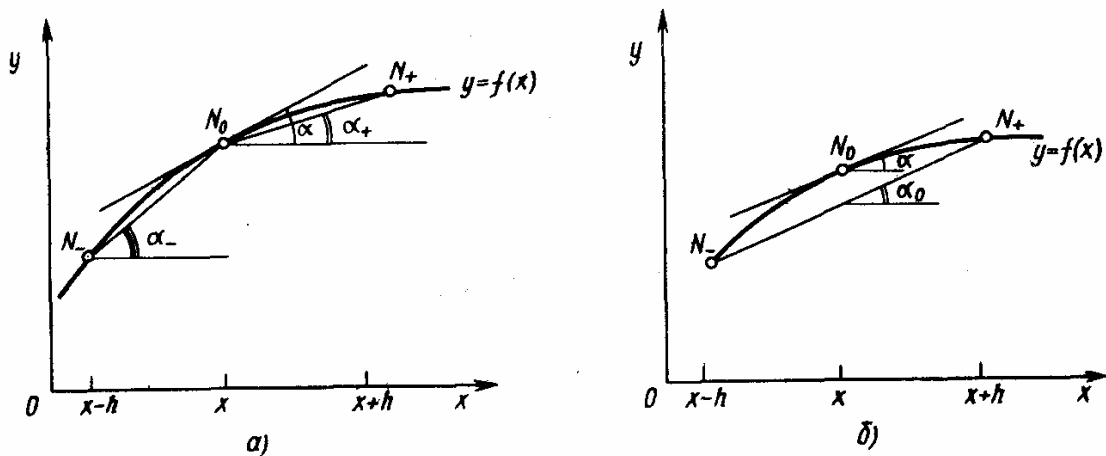


Рис. 12.1

Приведенные формулы численного дифференцирования имеют простую геометрическую интерпретацию (рис. 12.1, а). Пусть  $N_0$ ,  $N_-$  и  $N_+$  — расположенные на графике функции  $y = f(x)$  точки с координатами  $(x, f(x))$ ,  $(x - h, f(x - h))$  и  $(x + h, f(x + h))$ . Напомним, что производная  $f'(x)$  равна тангенсу угла  $\alpha$  наклона к оси  $Ox$  касательной, проведенной к графику функции в точке  $N_0$ . Формула (12.1) соответствует приближенной замене производной  $f'(x) = \operatorname{tg} \alpha$  правой разностной производной  $\frac{f(x + h) - f(x)}{h}$ , равной тангенсу угла  $\alpha_+$  наклона к графику функции секущей, проведенной через точки  $N_0$  и  $N_+$ . Формула (12.2) соответствует аналогичной замене левой разностной производной  $\frac{f(x) - f(x - h)}{h}$ , равной тангенсу угла  $\alpha_-$  секущей, проведенной через точки  $N_0$  и  $N_-$ .

Естественно предположить (рис. 12.1, а и 12.1, б), что лучшим по сравнению с  $\operatorname{tg} \alpha_+$  и  $\operatorname{tg} \alpha_-$  приближением к  $f'(x) = \operatorname{tg} \alpha$  является тангенс угла наклона  $\alpha_0$  секущей к графику, проведенной через точки  $N_-$  и  $N_+$ . Соответствующая приближенная формула имеет вид

$$f'(x) \approx \frac{f(x + h) - f(x - h)}{2h} \quad (12.6)$$

Величину в правой части этой формулы часто называют *центральной разностной производной*.

Подставляя в выражение для погрешности

$$r_0(x, h) = f'(x) - \frac{f(x + h) - f(x - h)}{2h}$$

соответствующие разложения по формуле Тейлора

$$f(x \pm h) = f(x) \pm f'(x)h + \frac{f''(x)}{2} h^2 \pm \frac{f^{(3)}(\xi_{\pm})}{6} h^3,$$

получим,  $r_0(x, h) = -\frac{f^{(3)}(\xi_+) + f^{(3)}(\xi_-)}{12} h^2$ . Следовательно, справедливая оценка погрешности

$$|r_0(x, h)| \leq \frac{M_3}{6} h^2, \quad M_3 = \max_{[x-h, x+h]} |f^{(3)}(\xi)| \quad (12.7)$$

Таким образом, центральная разностная производная аппроксимирует производную  $f'(x)$  со вторым порядком точности относительно  $h$ .

Для вычисления  $f'(x)$  можно получить формулы любого порядка точности (см. § 12.2). Однако в таких формулах с ростом порядка точности возрастает и число используемых значений функции. В качестве примера приведем формулу

$$f'(x) \approx \frac{f(x-2h) - 8f(x-h) + 8f(x+h) - f(x+2h)}{12h}, \quad (12.8)$$

имеющую четвертый порядок точности.

**Пример 12.1.** Пусть функция  $f(x) = e^x$  задана на отрезке  $[0, 1]$  таблицей значений с шагом  $h = 0.2$ :

Т а б л и ц а 12.1

$x$	0.0	0.2	0.4	0.6	0.8	1.0
$f(x)$	1.000000	1.22140	1.49182	1.82212	2.22554	2.71828

Используя формулы численного дифференцирования, найдем значения производной  $f'(x)$  в узлах таблицы.

В точках  $x = 0.0$  и  $x = 1.0$  из приведенных в этом параграфе формул можно воспользоваться лишь формулами (12.1) и (12.2). В остальных точках применим формулу (12.6), имеющую более высокий порядок точности. Вычисления дают следующую таблицу производных:

Т а б л и ц а 12.2

$x$	0.0	0.2	0.4	0.6	0.8	1.0
$f'(x)$	1.10700	1.22955	1.50180	1.83430	2.24040	2.46370
$r(x)$	-0.10700	-0.00815	-0.00998	-0.01218	-0.01486	0.25458

Здесь же приведены значения погрешностей  $r(x)$ , которые в данном случае легко вычисляются (ведь  $f'(x) = e^x = f(x)$ ). Как и следовало ожидать, значения погрешности в крайних точках (здесь использовались формулы первого порядка точности) существенно больше, чем во внутренних точках.

Заметим, что значения погрешностей можно было оценить и заранее, используя априорные оценки (12.4), (12.5), (12.7). Например, неравенство (12.4) дает в точке  $x = 0$  оценку

$$|r| \leq \frac{1}{2} M_2 h = \frac{1}{2} \max_{[0, 0.2]} |e^x| \cdot h = \frac{1}{2} \cdot 1.22140 \cdot 0.2 \approx 0.13.$$

В точке  $x = 0.2$  из неравенства (12.7) следует, что

$$|r| \leq \frac{1}{6} M_3 h^2 = \frac{1}{6} \max_{[0, 0.4]} |e^\xi| h^2 = \frac{1}{6} \cdot 1.49182 \cdot 0.04 \approx 0.01, \text{ и т.д.}$$

Для вычисления  $f'(x)$  при  $x = 0.4$  и  $x = 0.6$  можно также применить формулу (12.8) и получить значения  $f'(0.4) \approx 1.49176$  и  $f'(0.6) \approx 1.82203$  с погрешностями, приближенно равными  $6 \cdot 10^{-5}$  и  $9 \cdot 10^{-5}$  соответственно.

**2. Вычисление второй производной.** Наиболее простой и широко применяемой для приближенного вычисления второй производной является следующая формула:

$$f''(x) \approx \frac{f(x-h) - 2f(x) + f(x+h)}{h^2}. \quad (12.9)$$

Величину в правой части этого приближенного равенства часто называют *второй разностной производной* [70].

Подставляя в выражение для погрешности

$$r(x, h) = f''(x) - \frac{f(x-h) - 2f(x) + f(x+h)}{h^2}.$$

соответствующие разложения по формуле Тейлора

$$f(x \pm h) = f(x) \pm f'(x)h + \frac{f''(x)}{2} h^2 \pm \frac{f^{(3)}(x)}{6} h^3 + \frac{f^{(4)}(\xi_{\pm})}{24} h^4,$$

получим  $r(x, h) = -\frac{f^{(4)}(\xi_+) + f^{(4)}(\xi_-)}{24} h^2$ . Следовательно,

$$|r(x, h)| \leq \frac{M_4}{12} h^2, \quad M_4 = \max_{[x-h, x+h]} |f^{(4)}(\xi)|. \quad (12.10)$$

Таким образом, формула (12.9) имеет второй порядок точности.

Для вычисления  $f''(x)$  можно получить формулы любого порядка точности. Например, формула

$$f''(x) \approx \frac{-f(x-2h) + 16f(x-h) - 30f(x) + 16f(x+h) - f(x+2h)}{12h^2} \quad (12.11)$$

имеет четвертый порядок точности.

**Пример 12.2.** Используя табл. 12.1 значений функции  $f(x) = e^x$ , найдем с помощью формул численного дифференцирования значения  $f''(x)$  во внутренних узлах таблицы.

Вычисление по формуле (12.9) дает значения, приведенные в табл. 12.3:

Т а б л и ц а 12.3

$x$	0.2	0.4	0.6	0.8
$f''(x)$	1.22550	1.49700	1.82800	2.23300
$r(x)$	-0.00410	-0.00518	-0.00588	-0.00746

Применение формулы (12.11) позволяет получить значения  $f''(0.4) \approx 1.49204$ ,  $f''(0.6) \approx 1.82183$  с погрешностями, приближенно равными  $-2 \cdot 10^{-4}$ ,  $-3 \cdot 10^{-4}$ .

## § 12.2. О выводе формул численного дифференцирования

Хотя простейшие формулы численного дифференцирования можно получить сравнительно элементарно, для вывода и анализа таких формул в более сложных случаях необходимо использовать значительно более серьезный математический аппарат. Заметим, что основой для построения различных приближенных формул вычисления производных являются методы теории приближения функций, элементы которой были изложены в предыдущей главе.

Предположим, что в окрестности точки  $x$  функция  $f$  аппроксимируется некоторой другой функцией  $g$ , причем производная  $g^{(k)}$  в точке  $x$  легко вычисляется. Естественно в такой ситуации попытаться воспользоваться приближенной формулой

$$f^{(k)}(x) \approx g^{(k)}(x). \quad (12.12)$$

Наиболее просто этот подход реализуется в случае, когда приближение осуществляется с помощью интерполяции.

**1. Формулы численного дифференцирования, основанные на интерполяции алгебраическими многочленами.** Пусть  $P_n(x)$  — интерполяционный многочлен степени  $n$  с узлами интерполяции  $x_0 < x_1 < x_2 < \dots < x_n$  и  $x \in [x_0, x_n]$ . В этом случае формула (12.12) принимает вид

$$f^{(k)}(x) \approx P_n^{(k)}(x), \quad 0 \leq k \leq n. \quad (12.13)$$

При этом справедлива следующая оценка погрешности формулы (12.13):

$$|f^{(k)}(x) - P_n^{(k)}(x)| \leq C_{n,k} M_{n+1} h_{\max}^{n+1-k}, \quad 0 \leq k \leq n. \quad (12.14)$$

Здесь  $C_{n,k}$  — положительные числа, а  $M_{n+1} = \max_{[x_0, x_n]} |f^{(n+1)}(x)|$ .

**З а м е ч а н и е 1.** Порядок точности формулы (12.13) относительно  $h_{\max}$  равен разности между числом узлов интерполяции и порядком вычисляемой производной.

**З а м е ч а н и е 2.** Если формула (12.13) применяется для вычисления производной в точке, относительно которой узлы таблицы расположены симметрично, и число  $n - k$  четно, то порядок точности формулы повышается на единицу по сравнению с порядком  $n + 1 - k$ , гарантируемым оценкой (12.14). Таковы, например, формулы (12.6), (12.8), (12.9), (12.11).

Заметим, что  $P_n^{(n)}(x) = n! f(x_0; x_1; \dots, x_n)$  (это следует, в частности, из формулы (11.52)). Таким образом, справедлива приближенная формула (она вытекает и из (11.50))

$$f^{(n)}(x) \approx n! f(x_0; x_1; \dots, x_n), \quad (12.15)$$

имеющая по крайней мере первый порядок точности. Ее частными случаями являются следующие формулы:

$$f'(x) \approx f(x_0; x_1) = \frac{f(x_1) - f(x_0)}{x_1 - x_0}, \quad (12.16)$$

$$f''(x) \approx 2f(x_0; x_1; x_2) = \frac{2}{x_2 - x_0} \left[ \frac{f(x_2) - f(x_1)}{x_2 - x_1} - \frac{f(x_1) - f(x_0)}{x_1 - x_0} \right] \quad (12.17)$$

При выборе в качестве узлов интерполяции значений  $x_0 = x$ ,  $x_1 = x + h$  формула (12.16) превращается в формулу (12.1). При выборе  $x_0 = x - h$ ,  $x_1 = x$  из (12.16) получается формула (12.2), а при  $x_0 = x - h$ ,  $x_1 = x + h$  — формула (12.6). Аналогично из формулы (12.17) получается формула (12.9).

**2. Использование таблиц с постоянным шагом.** Наиболее простой вид принимают формулы численного дифференцирования при исполь-

зовании таблиц  $y_i = f(x_i)$  с постоянным шагом. Например, формула (12.15) в этом случае выглядит так:  $f^{(n)}(x) \approx \frac{\Delta^n y_0}{h^n}$ .

В тех случаях, когда значение производной необходимо вычислять в крайних для таблицы точках  $x_0$  и  $x_n$ , используются *односторонние формулы численного дифференцирования*  $f^{(k)}(x_0) \approx P_n^{(k)}(x_0)$  и  $f^{(k)}(x_n) \approx P_n^{(k)}(x_n)$ . Приведем односторонние формулы (их легко получить дифференцированием многочленов Ньютона (11.57) и (11.58)) для вычисления первой производной  $f'$ :

$$f'(x_0) \approx \frac{1}{h} \sum_{j=1}^n \frac{(-1)^{j-1}}{j} \Delta^j y_0, \quad (12.18)$$

$$f'(x_n) \approx \frac{1}{h} \sum_{j=1}^n \frac{1}{j} \nabla^j y_n, \quad (12.19)$$

имеющие  $n$ -й порядок точности.

При  $n = 2$  из (12.18), (12.19) получаются формулы

$$f'(x_0) \approx \frac{1}{2h} (-3f(x_0) + 4f(x_1) - f(x_2)), \quad (12.20)$$

$$f'(x_n) \approx \frac{1}{2h} (f(x_{n-2}) - 4f(x_{n-1}) + 3f(x_n)), \quad (12.21)$$

имеющие второй порядок точности.

**Пример 12.3.** Вычисление значений производной функции  $f(x) = e^x$ , заданной табл. 12.1, по формулам (12.20), (12.21) дает значения  $f'(0.0) \approx 0.98445$ ,  $f'(1.0) \approx 2.68700$  с погрешностями, равными 0.001555 и 0.03128. Для сравнения напомним, что погрешности значений, найденных в примере 12.1 по простейшим формулам (12.1), (12.2) соответственно равны — 0.10700 и 0.25458.

**3. Другие подходы.** Применение формулы (12.13) для вычисления производной  $f^{(k)}$  фактически основано на кусочно-полиномиальной интерполяции. Полученная таким образом производная в точке "стыка" двух соседних многочленов может иметь разрыв. Поэтому, если требуется глобально на отрезке  $[a, b]$  аппроксимировать производную гладкой функцией, то целесообразно использовать сплайны. Производ-



ная  $S_m^{(k)}(x)$  сплайна  $S_m(x)$  при  $k \leq m - r$  (где  $r$  — дефект сплайна) дает гладкую глобальную аппроксимацию для  $f^{(k)}(x)$ .

В случае, когда значения функции сильно "зашумлены" случайными ошибками, полезным может оказаться использование метода наименьших квадратов.

### § 12.3. Обусловленность формул численного дифференцирования

Несмотря на внешнюю простоту формул численного дифференцирования, их применение требует особой осторожности. Отметим, что используемые при численном дифференцировании значения  $f^*(x)$  функции  $f(x)$  непременно содержат ошибки. Поэтому к погрешности аппроксимации формул численного дифференцирования добавляется неустраняемая погрешность, вызванная погрешностями вычисления функции  $f$ . Для того чтобы погрешность аппроксимации была достаточно малой, требуется использование таблиц с малыми шагами  $h$ . Однако, к сожалению, при малых шагах формулы численного дифференцирования становятся плохо обусловленными и результат их применения может быть полностью искажен неустраняемой ошибкой. Важно понимать, что действительная причина этого явления лежит не в несовершенстве предложенных методов вычисления производных, а в некорректности самой операции дифференцирования приближенно заданной функции (см. гл. 3, пример 3.5).

Поясним сказанное на примере использования формулы (12.1). Полная погрешность  $r^*(x, h) = f'(x) - \frac{f^*(x+h) - f^*(x)}{h}$  реально вычисляемого значения правой разностной производной представляет собой сумму погрешности аппроксимации  $r_+(x, h) = f'(x) - \frac{f(x+h) - f(x)}{h}$  и неустраняемой погрешности  $r_n(x, h) = \frac{1}{h} ((f(x+h) - f^*(x+h)) - (f(x) - f^*(x)))$ .

Пусть  $\bar{\Delta}$  — верхняя граница абсолютной погрешности  $\Delta(f^*(x)) = |f(x) - f^*(x)|$  используемых значений функции. Тогда погрешность  $r_n$  оценивается следующим образом:

$$|r_n| \leq \frac{2\bar{\Delta}}{h}. \quad (12.22)$$

Оценка (12.22) означает, что чувствительность формулы (12.1) к погрешностям входных данных характеризуется абсолютным числом

обусловленности  $\nu_{\Delta} = \frac{2}{h}$ . Так как  $\nu_{\Delta} \rightarrow \infty$  при  $h \rightarrow 0$ , то формула (12.1) при малых  $h$  становится очень плохо обусловленной. Поэтому несмотря на то, что погрешность аппроксимации стремится к нулю при  $h \rightarrow 0$  (см. оценку (12.4)), следует ожидать, что полная погрешность будет неограниченно возрастать при  $h \rightarrow 0$ . Во всяком случае так ведет себя верхняя граница полной погрешности  $\bar{r}(h) = \frac{1}{2} M_2 h + \frac{2\bar{\Delta}}{h}$  (график функции  $\bar{r}(h)$  для случая, рассмотренного в примере 12.4, приведен на рис. 12.2).

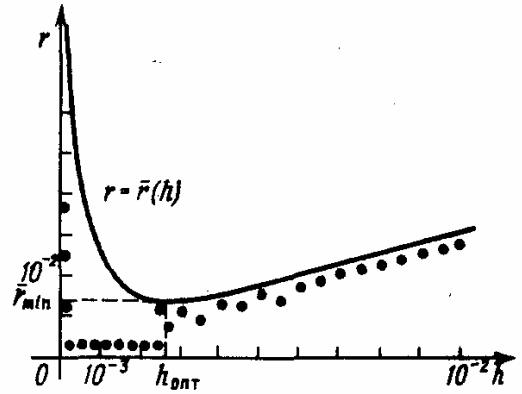


Рис. 12.2

Выберем оптимальное значение шага  $h$ , при котором величина  $\bar{r}(h)$  достигает минимального значения.

Приравнивая производную  $\bar{r}'(h) = \frac{1}{2} M_2 - \frac{2\bar{\Delta}}{h^2}$  к нулю, получаем

значение  $h_{\text{опт}} = 2\sqrt{\bar{\Delta}/M_2}$ , которому отвечает величина  $\bar{r}_{\text{мин}} = \bar{r}(h_{\text{опт}}) = 2\sqrt{\bar{\Delta}M_2}$ .

Таким образом, при использовании формулы (12.1) для вычисления производной функции  $f$ , заданной с погрешностью, следует обратить особое внимание на выбор шага  $h$ . Однако даже при оптимальном выборе шага полная погрешность окажется величиной, пропорциональной лишь  $\sqrt{\bar{\Delta}}$ .

Формулы для вычисления производных порядка  $k > 1$  обладают еще большей чувствительностью к ошибкам задания функций. Поэтому значения производных высокого порядка, найденные с помощью таких формул, могут быть очень неточными.

**Пример 12.4.** Рассмотрим результаты применения формулы (12.1) с разными значениями шага  $h$  для вычисления производной функции  $f(x) = e^x$  в точке  $x = 1$ .

В табл. 12.4 приведены значения приближений  $(f')^*$  к  $f'(1) = e \approx 2.71828$ , полученные на 6-разрядной десятичной ЭВМ и отвечающие значениям  $h = 10^{-1}, 10^{-2}, \dots, 10^{-6}$ . Для удобства анализа указаны также значения погрешностей  $r^*$ .

Т а б л и ц а 12.4

$h$	$10^{-1}$	$10^{-2}$	$10^{-3}$	$10^{-4}$	$10^{-5}$	$10^{-6}$
$(f')^*$	2.85890	2.73200	2.72000	2.70000	3.00000	0.00000
$r^*$	$14 \cdot 10^{-2}$	$14 \cdot 10^{-3}$	$17 \cdot 10^{-4}$	$-18 \cdot 10^{-3}$	$28 \cdot 10^{-2}$	$-27 \cdot 10^{-1}$

Из таблицы видно, что погрешность  $r^*$  с уменьшением  $h$  сначала убывает по модулю, а затем начинает резко возрастать. При  $h = 10^{-6}$  значения функции в точках  $x = 1 + h$  и  $x = 1$ , найденные с шестью знаками мантиссы, совпадают, и поэтому вычисление по формуле (12.1) даёт приближение к  $f'(1)$ , равное нулю. Ясно, что при  $h < 10^{-6}$  будет получаться тот же результат.

На рис. 12.2 точками помечены значения модуля погрешности  $r^*$ , отвечающие различным  $h$  из диапазона  $10^{-4} \leq h \leq 10^{-2}$ . Сплошной линией изображен график функции  $\bar{r}(h) = 1.4h + \frac{10^{-5}}{h}$ , являющейся верхней оценкой для

$|r^*(h)|$  (в данном случае  $M_2 = \max_{[1, 1.01]} |e^x| \leq 2.8$  и  $\bar{\Delta} = 5 \cdot 10^{-6}$ ). Отметим,

что хотя реальное значение погрешности  $r^*$  и оказывается меньше получаемого с помощью оценки  $\bar{r}$ , все же функция  $\bar{r}(h)$  правильно отражает основные особенности поведения погрешности.

## § 12.4. Дополнительные замечания

1. Формулы численного дифференцирования применяются и для приближенного вычисления частных производных функций многих переменных. Для их построения используются различные приемы. Среди них последовательное применение одномерных формул численного дифференцирования и дифференцирование интерполяционных формул. Распространенным является и метод неопределенных коэффициентов [9] (иногда он используется и в одномерном случае).

2. При наличии в значениях функции случайных ошибок нередко применяют некоторые процедуры предварительного сглаживания. В последнее время получила распространение группа методов численного дифференцирования, в которых используются идеи регуляризации (см. [79, гл. 4, § 6]).

3. Дополнительную информацию о методах численного дифференцирования можно найти, например, в [43].

## Глава 13

### ЧИСЛЕННОЕ ИНТЕГРИРОВАНИЕ

#### § 13.1. Простейшие квадратурные формулы

1. **Постановка задачи.** В прикладных исследованиях часто возникает необходимость вычисления значения определенного интеграла

$$I = \int_a^b f(x) dx \quad (13.1)$$

Этот интеграл может выражать площадь, объем, работу переменной силы и т.д.

Если функция  $f(x)$  непрерывна на отрезке  $[a, b]$  и ее первообразную  $F(x)$  удастся выразить через известные функции, то для вычисления интеграла (13.1) можно воспользоваться *формулой Ньютона-Лейбница*<sup>1</sup>:

$$\int_a^b f(x) dx = F(b) - F(a). \quad (13.2)$$

К сожалению, в подавляющем большинстве случаев получить значение определенного интеграла с помощью формулы (13.2) или других аналитических методов не удастся.

**Пример 13.1.** Интеграл  $\int_0^x e^{-t^2} dt$  широко используется при исследовании процессов теплообмена и диффузии, в статистической физике и теории вероятностей. Однако его значение не может быть выражено в виде конечной комбинации элементарных функций.

---

<sup>1</sup> Готфрид Вильгельм Лейбниц (1646 — 1716) — немецкий математик, физик и философ. Один из создателей дифференциального и интегрального исчисления.

Заметим, что даже в тех случаях, когда удастся получить первообразную функцию  $F(x)$  в аналитической форме, значительные усилия, затраченные на это, часто оказываются чрезмерно высокой платой за окончательный результат. Добавим еще, что вычисления интеграла в этих случаях по формуле (13.2), как правило, приводят к громоздким (а часто — и приближенным) вычислениям. Следует отметить также, что зачастую найти точное значение интеграла (13.1) просто невозможно. Например, это имеет место, когда функция  $f(x)$  задается таблицей своих значений.

Обычно для вычисления значения определенного интеграла применяют специальные численные методы. Наиболее широко используют на практике *квадратурные формулы* — приближенные равенства вида

$$\int_a^b f(x)dx \approx \sum_{i=0}^N A_i f(\bar{x}_i). \quad (13.3)$$

Здесь  $\bar{x}_i$  — некоторые точки из отрезка  $[a, b]$  — *узлы квадратурной формулы*;  $A_i$  — числовые коэффициенты, называемые *весами квадратурной формулы*;  $N \geq 0$  — целое число. Сумма  $\sum_{i=0}^N A_i f(\bar{x}_i)$ , которая принимается за приближенное значение интеграла, называется *квадратурной суммой*. Величина  $R = \int_a^b f(x)dx - \sum_{i=0}^N A_i f(\bar{x}_i)$  называется *погрешностью* (или *остаточным членом*) *квадратурной формулы*.

Будем говорить, что квадратурная формула (13.3) *точна для многочленов степени  $m$* , если для любого многочлена степени не выше  $m$  эта формула дает точное значение интеграла, т.е.

$$\int_a^b P_m(x)dx = \sum_{i=0}^N A_i P_m(\bar{x}_i).$$

При оценке эффективности квадратурных формул часто исходят из того, что наиболее трудоемкой операцией при вычислении по формуле (13.3) является нахождение значения функции  $f$ . Поэтому среди двух формул, позволяющих вычислить интеграл с заданной точностью  $\epsilon$ , более эффективной считается та, в которой используется меньшее число узлов.

Выведем простейшие квадратурные формулы, исходя из наглядных геометрических соображений. Будем интерпретировать интеграл (13.1), как площадь криволинейной трапеции, ограниченной графиком функции  $y = f(x)$  (при  $f(x) \geq 0$ ), осью абсцисс и прямыми  $x = a$ ,  $x = b$  (рис. 13.1, а).

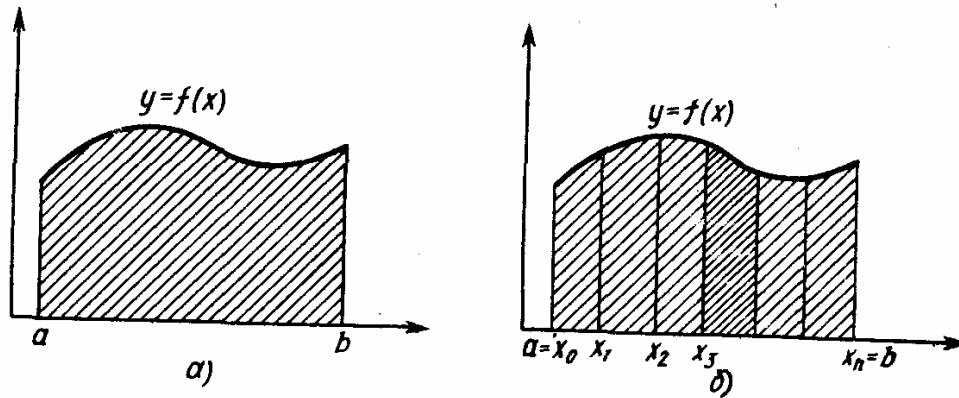


Рис. 13.1

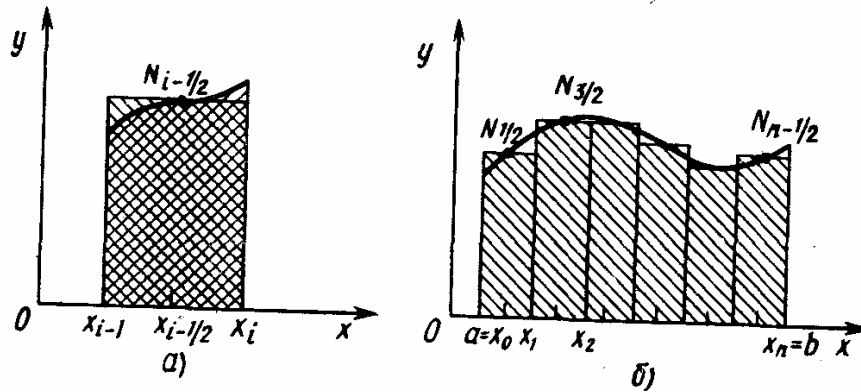


Рис. 13.2

Разобьем отрезок  $[a, b]$  на элементарные отрезки  $[x_{i-1}, x_i]$  точками  $a = x_0 < x_1 < \dots < x_n = b$ . Интеграл  $I$  разобьется при этом на сумму элементарных интегралов:

$$I = \sum_{i=1}^n I_i, \quad (13.4)$$

где  $I_i = \int_{x_{i-1}}^{x_i} f(x) dx$ , что соответствует разбиению площади исходной криволинейной трапеции на сумму площадей элементарных криволинейных трапеций (рис. 13.1, б).

Введем обозначения:  $f_i = f(x_i)$ ,  $f_{i-1/2} = f(x_{i-1/2})$ , где  $x_{i-1/2} = (x_{i-1} + x_i)/2$  — середина элементарного отрезка. Для простоты шаг  $h = x_i - x_{i-1}$  будем считать постоянным.

**2. Формула прямоугольников.** Заменяем приближенно площадь элементарной криволинейной трапеции площадью прямоугольника, основанием которого является отрезок  $[x_{i-1}, x_i]$ , а высота равна значению  $f_{i-1/2}$  (на рис. 13.2, а через  $N_{i-1/2}$  обозначена точка с координатами  $(x_{i-1/2}, f_{i-1/2})$ ). Так мы приходим к элементарной квадратной формуле прямоугольников:

$$I_i \approx h f_{i-1/2}. \quad (13.5)$$

Производя такую замену для всех элементарных криволинейных трапеций, получаем *составную квадратурную формулу прямоугольников*:

$$I \approx I_{\text{пр}}^h = h (f_{1/2} + f_{3/2} + \dots + f_{n-1/2}) = h \sum_{i=1}^n f_{i-1/2}. \quad (13.6)$$

Эта формула соответствует приближенной замене площади исходной криволинейной трапеции площадью ступенчатой фигуры, изображенной на рис. 13.2, б.

**З а м е ч а н и е.** Иногда используют формулы

$$I \approx h \sum_{i=0}^{n-1} f_i, \quad (13.7)$$

$$I \approx h \sum_{i=1}^n f_i, \quad (13.8)$$

называемые соответственно *составными квадратурными формулами левых и правых прямоугольников*. Геометрические иллюстрации приведены на рис. 13.3, а и б. В соответствии с этим формулу (13.6) иногда называют *составной квадратурной формулой центральных прямоугольников*.

**3. Формула трапеций.** Соединив отрезком точки  $N_{i-1}(x_{i-1}, f_{i-1})$  и  $N_i(x_i, f_i)$  на графике функции  $y = f(x)$ , получим трапецию (рис. 13.4, а). Заменим теперь приближенно площадь элементарной криволинейной трапеции площадью построенной фигуры. Тогда получим *элементарную квадратурную формулу трапеций*:

$$I_i \approx \frac{h}{2} (f_{i-1} + f_i). \quad (13.9)$$

Пользуясь этой формулой при  $i = 1, \dots, n$ , выводим *составную квадратурную формулу трапеций*:

$$\begin{aligned} I \approx I_{\text{тр}}^h &= h \left[ \frac{f_0}{2} + f_1 + f_2 + \dots + f_{n-1} + \frac{f_n}{2} \right] = \\ &= h \left[ \frac{f_0 + f_n}{2} + \sum_{i=1}^n f_i \right]. \end{aligned} \quad (13.10)$$

Эта формула соответствует приближенной замене площади исходной

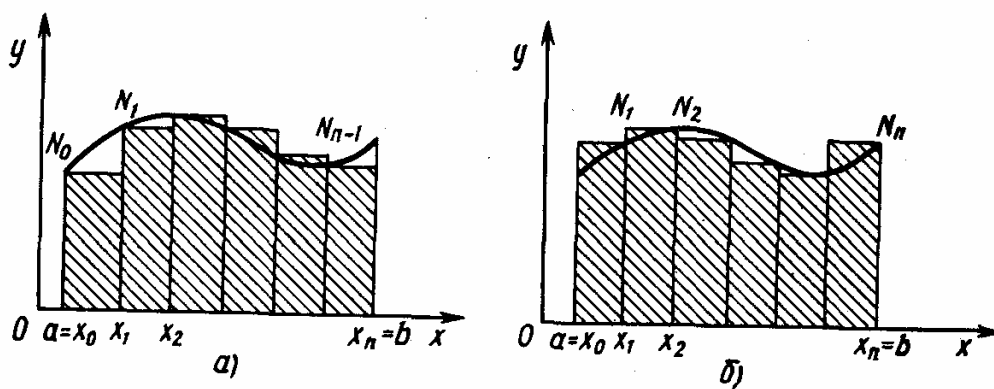


Рис. 13.3

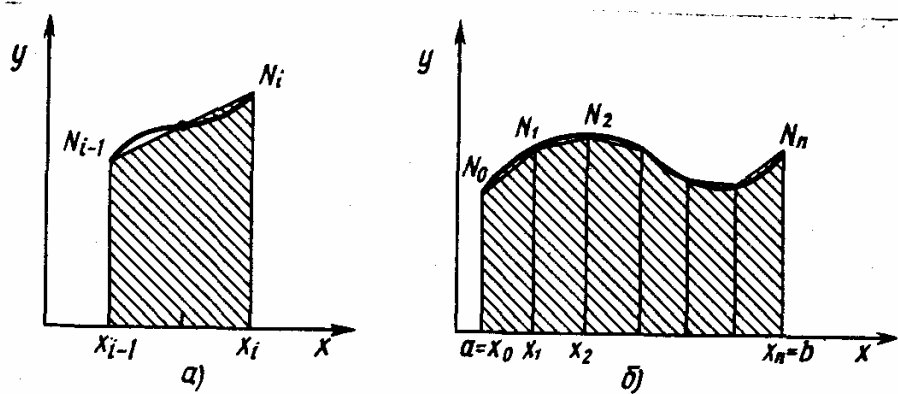


Рис. 13.4

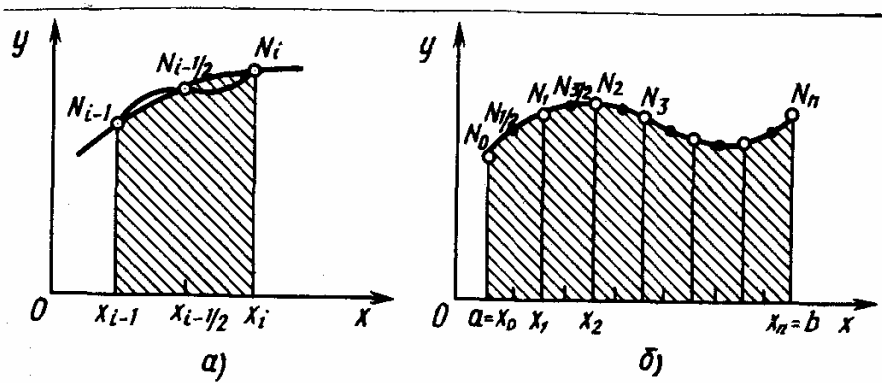


Рис. 13.5



криволинейной трапеции площадью фигуры, ограниченной ломаной линией, проходящей через точки  $N_0, N_1, \dots, N_n$  (рис. 13.4, б).

**4. Формула Симпсона<sup>1</sup>.** Если площадь элементарной криволинейной трапеции заменить площадью фигуры, расположенной под параболой, проходящей через точки  $N_{i-1}, N_{i-1/2}$  и  $N_i$  (рис. 13.5, а), то полу-

чим приближенное равенство  $I_i \approx \int_{x_{i-1}}^{x_i} P_2(x) dx$ . Здесь  $P_2(x)$  — интерполяционный многочлен второй степени с узлами  $x_{i-1}, x_{i-1/2}, x_i$ . Как нетрудно убедиться<sup>2</sup>, верна формула

$$P_2(x) = f_{i-1/2} + \frac{f_i - f_{i-1}}{h} (x - x_{i-1/2}) + \\ + \frac{f_i - 2f_{i-1/2} + f_{i-1}}{h^2/2} (x - x_{i-1/2})^2.$$

Ее интегрирование приводит к равенству

$$\int_{x_{i-1}}^{x_i} P_2(x) dx = hf_{i-1/2} + \frac{f_i - f_{i-1}}{h} \int_{x_{i-1}}^{x_i} (x - x_{i-1/2}) dx + \\ + \frac{f_i - 2f_{i-1/2} + f_{i-1}}{h^2/2} \int_{x_{i-1}}^{x_i} (x - x_{i-1/2})^2 dx = \\ = hf_{i-1/2} + \frac{h}{6} (f_i - 2f_{i-1/2} + f_{i-1}) = \frac{h}{6} (f_{i-1} + 4f_{i-1/2} + f_i).$$

Таким образом, выведена элементарная квадратурная формула Симпсона:

$$I_i \approx \frac{h}{6} (f_{i-1} + 4f_{i-1/2} + f_i). \quad (13.11)$$

Применяя эту формулу на каждом элементарном отрезке, выводим составную квадратурную формулу Симпсона:

<sup>1</sup> Томас Симпсон (1710—1761) — английский математик.

<sup>2</sup> Проверку того, что  $P_2(x_{i-1}) = f_{i-1}$ ,  $P_2(x_{i-1/2}) = f_{i-1/2}$ ,  $P_2(x_i) = f_i$ , рекомендуем провести самостоятельно.

$$I \approx I_C^h = \frac{h}{6} (f_0 + 4f_{1/2} + 2f_1 + 4f_{3/2} + 2f_2 + \dots + 2f_{n-1} + 4f_{n-1/2} + f_n) = \frac{h}{6} (f_0 + f_n + 4 \sum_{i=1}^n f_{i-1/2} + 2 \sum_{i=1}^{n-1} f_i). \quad (13.12)$$

**З а м е ч а н и е 1.** Учитывая геометрическую интерпретацию формулы Симпсона, ее иногда называют *формулой парабол*.

**З а м е ч а н и е 2.** В случае, когда число элементарных отрезков разбиения четно ( $n = 2m$ ), в формуле Симпсона можно использовать лишь узлы с целыми индексами:

$$I \approx \frac{h}{3} (f_0 + f_{2m} + 4 \sum_{i=1}^m f_{2i-1} + 2 \sum_{i=1}^{m-1} f_{2i}).$$

При выводе этой формулы роль элементарного отрезка играет отрезок  $[x_{2i-2}, x_{2i}]$  длины  $2h$ .

**5. Оценка погрешности.** Оценим погрешность выведенных квадратурных формул в предположении, что подынтегральная функция  $f$  достаточно гладкая. Как и в предыдущих главах, будем использовать обозначение  $M_k = \max_{[a, b]} |f^{(k)}(x)|$ .

**Т е о р е м а 13.1.** Пусть функция  $f$  дважды непрерывно дифференцируема на отрезке  $[a, b]$ . Тогда для составных квадратурных формул прямоугольников и трапеций справедливы следующие оценки погрешности:

$$|I - I_{\text{пр}}^h| \leq \frac{M_2(b-a)}{24} h^2, \quad (13.13)$$

$$|I - I_{\text{тр}}^h| \leq \frac{M_2(b-a)}{12} h^2. \quad (13.14)$$

□ Выведем сначала оценку (13.13). Представим погрешность  $R = I - I_{\text{пр}}^h$  формулы прямоугольников в виде

$$R = \int_a^b f(x) dx - h \sum_{i=1}^n f_{i-1/2} = \sum_{i=1}^n \int_{x_{i-1}}^{x_i} (f(x) - f(x_{i-1/2})) dx.$$

Используя формулу Тейлора

$$f(x) = f(x_{i-1/2}) + f'(x_{i-1/2})(x - x_{i-1/2}) + \frac{f''(\xi)}{2} (x - x_{i-1/2})^2,$$

где  $x \in [x_{i-1}, x_i]$ ,  $\xi = \xi(x) \in [x_{i-1}, x_i]$ , имеем

$$R_i = \int_{x_{i-1}}^{x_i} (f(x) - f(x_{i-1/2})) dx = \frac{1}{2} \int_{x_{i-1}}^{x_i} f''(\xi(x))(x - x_{i-1/2})^2 dx,$$

$$|R_i| \leq \frac{M_2}{2} \int_{x_{i-1}}^{x_i} (x - x_{i-1/2})^2 dx = \frac{M_2}{6} (x - x_{i-1/2})^3 \Big|_{x_{i-1}}^{x_i} = \frac{M_2}{24} h^3.$$

Так как  $R = \sum_{i=1}^n R_i$ , то  $|R| \leq \sum_{i=1}^n \frac{M_2}{24} h^3 = \frac{M_2}{24} h^3 n$ . Замечая, что  $nh = b - a$ , приходим к оценке (13.13).

Для вывода оценки (13.14) воспользуемся тем, что отрезок, соединяющий точки  $N_{i-1}$  и  $N_i$  представляет собой график интерполяционного многочлена первой степени  $y = P_1(x) = f_{i-1} \frac{x_i - x}{h} + f_i \frac{x - x_{i-1}}{h}$ . Поэтому для элементарной формулы трапеций верно равенство

$$R_i = \int_{x_{i-1}}^{x_i} f(x) dx - \frac{h}{2} (f_{i-1} + f_i) = \int_{x_{i-1}}^{x_i} (f(x) - P_1(x)) dx.$$

Используя оценку (11.28) погрешности линейной интерполяции, имеем

$$|R_i| \leq \int_{x_{i-1}}^{x_i} \frac{M_2}{2} (x - x_{i-1})(x_i - x) dx = \frac{M_2}{12} h^3.$$

Следовательно, для  $R = I - I_{\text{тр}}^h$  справедлива оценка

$$|R| \leq \sum_{i=1}^n |R_i| \leq \frac{M_2}{12} h^3 n = \frac{M_2(b-a)}{12} h^2. \blacksquare$$

Приведем теперь без доказательства теорему об оценке погрешности формулы Симпсона.

**Т е о р е м а 13.2.** Пусть функция  $f$  имеет на отрезке  $[a, b]$  непрерывную производную четвертого порядка  $f^{(4)}$ . Тогда для формулы Симпсона (13.12) справедлива оценка погрешности

$$|I - I_C^h| \leq \frac{M_4(b-a)}{2880} h^4. \quad (13.15)$$

**З а м е ч а н и е 1.** Оценки (13.13), (13.14) и (13.15) означают, что формулы прямоугольников и трапеций имеют второй порядок точности относительно  $h$ , а формула Симпсона — четвертый порядок точности. Из тех же оценок следует, что формулы прямоуголь-

ников и трапеций точны для многочленов первой степени, а формула Симпсона — для многочленов третьей степени.

**З а м е ч а н и е 2.** Формулы (13.7) и (13.8) имеют лишь первый порядок точности (абсолютная погрешность каждой из формул не превышает  $0.5 M_1(b-a)h$ ) и поэтому для вычисления интегралов на практике они используются крайне редко.

**Пример 13.2.** Вычислим значение интеграла  $\int_0^1 e^{-x^2} dx$ , используя квадратурные формулы прямоугольников, трапеций и Симпсона с шагом  $h = 0.1$ .

Сначала составим таблицу значений функции  $y = e^{-x^2}$ :

Т а б л и ц а 13.1

$x$	$e^{-x^2}$	$x$	$e^{-x^2}$
0.00	1.0000000	0.55	0.7389685
0.05	0.9975031	0.60	0.6976763
0.10	0.9900498	0.65	0.6554063
0.15	0.9777512	0.70	0.6126264
0.20	0.9607894	0.75	0.5697828
0.25	0.9394131	0.80	0.5272924
0.30	0.9139312	0.85	0.4855369
0.35	0.8847059	0.90	0.4448581
0.40	0.8521438	0.95	0.4055545
0.45	0.8166865	1.00	0.3678794
0.50	0.7788008		

Производя вычисления по формулам (13.6), (13.10), (13.12), получим  $I_{\text{пр}}^h = 0.74713088$ ,  $I_{\text{тр}}^h = 0.74621079$ ,  $I_{\text{С}}^h = 0.74682418$ .

Оценим погрешность каждого из полученных значений, используя неравенства (13.13) — (13.15). Вычислим  $f^{(2)}(x) = (4x^2 - 2)e^{-x^2}$ . Как нетрудно видеть  $|f^{(2)}| \leq M_2 = 2$ . Следовательно,

$$I - I_{\text{пр}}^h \leq \frac{2 \cdot 1}{24} (0.1)^2 \approx 0.84 \cdot 10^{-3}, \quad |I - I_{\text{тр}}^h| \leq \frac{2 \cdot 1}{12} (0.1)^2 \approx 1.7 \cdot 10^{-3}.$$

Далее,  $f^{(4)}(x) = (16x^4 - 48x^2 + 12)e^{-x^2}$ ,  $|f^{(4)}| \leq 12$ . Поэтому

$$|I - I_{\text{С}}^h| \leq \frac{12 \cdot 1}{2880} (0.1)^4 \approx 0.42 \cdot 10^{-6}.$$

Таким образом, из вычислений по формуле прямоугольников с учетом погрешности следует, что  $I = 0.747 \pm 0.001$ ; по формуле трапеций — что  $I = 0.746 \pm 0.002$ ; по формуле Симпсона — что  $I = 0.7468242 \pm 0.0000005$ .

**6. Случай переменного шага.** Приведем составные квадратурные формулы прямоугольников, трапеций и Симпсона в случае переменного шага  $h_i = x_i - x_{i-1}$ .

$$I \approx I_{\text{пр}}^h = \sum_{i=1}^n f_{i-1/2} h_i,$$

$$I \approx I_{\text{тр}}^h = \sum_{i=1}^n \frac{f_{i-1} + f_i}{2} h_i,$$

$$I \approx I_{\text{с}}^h = \sum_{i=1}^n \frac{f_{i-1} + 4f_{i-1/2} + f_i}{6} h_i.$$

Вывод этих формул и их геометрический смысл остаются теми же, что и для случая постоянного шага. Теоремы об оценках погрешности также останутся справедливыми, если в неравенствах (13.13) – (13.15) заменить  $h$  на  $h_{\max} = \max_{1 \leq i \leq n} h_i$ .

### § 13.2. Квадратурные формулы интерполяционного типа

Для приближенного вычисления определенных интегралов часто используется следующий естественный для методов приближения функций прием. Подынтегральную функцию  $f$  аппроксимируют на отрезке  $[a, b]$  некоторой функцией  $g$ , интеграл от которой легко вычисляется, а затем полагают

$$\int_a^b f(x) dx \approx \int_a^b g(x) dx. \quad (13.16)$$

Точность формулы (13.16) можно повышать за счет усложнения метода глобальной аппроксимации. Однако чаще используется другой подход. Интеграл  $I$  представляют в виде суммы (13.4) интегралов по элементарным отрезкам  $[x_{i-1}, x_i]$ . На каждом таком  $i$ -м отрезке функцию  $f(x)$  аппроксимируют некоторой легко интегрируемой функцией  $g_i(x)$ . В результате получается составная формула

$$\int_a^b f(x) dx \approx \sum_{i=1}^n \int_{x_{i-1}}^{x_i} g_i(x) dx.$$

1. **Вывод квадратурных формул интерполяционного типа.** Рассмотрим более подробно этот подход в случае, когда аппроксимация осуществляется с помощью интерполяционного многочлена. Зафиксируем некоторые значения  $t_0, t_1, \dots, t_m \in [-1, 1]$ . Аппроксимируем функцию  $f(x)$  на  $i$ -м элементарном отрезке  $[x_{i-1}, x_i]$  интерполяционным многочленом  $P_{m,i}(x)$  с узлами интерполяции  $z_j^{(i)} = x_{i-1/2} + t_j h_i/2$ ,  $j = 0, 1, 2, \dots, m$ . В случае, когда все значения  $t_j$  различны, можно воспользоваться записью интерполяционного многочлена в форме Лагранжа:

$$P_{m,i}(x) = \sum_{j=0}^m f(z_j^{(i)}) l_{m,j}^{(i)}(x), \quad l_{m,j}^{(i)}(x) = \prod_{\substack{k=0 \\ k \neq j}}^m \frac{x - z_k^{(i)}}{z_j^{(i)} - z_k^{(i)}}. \quad (13.17)$$

Используя замену переменной  $x = x_{i-1/2} + \frac{th_i}{2}$ , вычислим интеграл от  $P_{m,i}$  на отрезке  $[x_{i-1}, x_i]$ :

$$\begin{aligned} \int_{x_{i-1}}^{x_i} P_{m,i}(x) dx &= \sum_{j=0}^m f(z_j^{(i)}) \int_{x_{i-1}}^{x_i} l_{m,j}^{(i)}(x) dx = \\ &= h_i \sum_{j=0}^m a_j f(x_{i-1/2} + t_j h_i/2), \quad a_j = \frac{1}{2} \int_{-1}^1 \prod_{\substack{k=0 \\ k \neq j}}^m \frac{(t - t_k)}{(t_j - t_k)} dt. \end{aligned}$$

Приближенная замена интеграла  $I$  суммой  $I^h = \sum_{i=1}^n \int_{x_{i-1}}^{x_i} P_{m,i}(x) dx$  приводит к следующей *составной квадратурной формуле интерполяционного типа*:

$$I \approx I^h = \sum_{i=1}^n h_i \sum_{j=0}^m a_j f(x_{i-1/2} + t_j h_i/2). \quad (13.18)$$

**З а м е ч а н и е.** Квадратурные формулы интерполяционного типа, построенные на основе равноотстоящих значений  $t_0, t_1, \dots, t_m$ , называют *формулами Ньютона—Котеса*<sup>1</sup>.

Рассмотренные в предыдущем параграфе простейшие квадратурные формулы являются формулами интерполяционного типа; более того,

---

<sup>1</sup> Роджер Котес (1682 — 1716) — английский математик, друг и ученик И. Ньютона.

они относятся к классу формул Ньютона—Котеса. Формулы прямоугольников (13.6), трапеций (13.10) и Симпсона (13.12) отвечают использованию интерполяционных многочленов соответственно нулевой, первой и второй степени.

**2. Оценка погрешности.** Приведем теорему об оценке погрешности формулы (13.18).

**Теорема 13.3.** Пусть функция  $f$  имеет на отрезке  $[a, b]$  непрерывную производную порядка  $m + 1$ . Тогда для погрешности квадратной формулы (13.18) справедлива оценка

$$|I - I^h| \leq C_m M_{m+1} (b - a) h_{\max}^{m+1}, \quad (13.19)$$

где

$$C_m = \frac{1}{2^{m+2}(m+1)!} \int_{-1}^1 |\bar{\omega}_{m+1}(t)| dt, \quad \bar{\omega}_{m+1}(t) = \prod_{k=0}^m (t - t_k).$$

□ Представим погрешность  $R = I - I^h$  формулы (13.18) в виде

$$R = \int_a^b f(x) dx - \sum_{i=1}^n \int_{x_{i-1}}^{x_i} P_{m,i}(x) dx = \sum_{i=1}^n \int_{x_{i-1}}^{x_i} (f(x) - P_{m,i}(x)) dx.$$

Пользуясь оценкой (11.26) погрешности интерполяции, в данном случае принимающей вид

$$|f(x) - P_{m,i}(x)| \leq \frac{M_{m+1}}{(m+1)!} \left| \prod_{k=0}^m (x - z_k^{(i)}) \right|,$$

и производя замену переменной  $x = x_{i-1/2} + th_i/2$ , получаем цепочку неравенств

$$\begin{aligned} |R| &\leq \sum_{i=1}^n \int_{x_{i-1}}^{x_i} |f(x) - P_{m,i}(x)| dx \leq \sum_{i=1}^n \frac{M_{m+1}}{(m+1)!} \int_{x_{i-1}}^{x_i} \left| \prod_{k=0}^m (x - z_k^{(i)}) \right| dx = \\ &= \sum_{i=1}^n \left[ \frac{h_i}{2} \right]^{m+2} \frac{M_{m+1}}{(m+1)!} \int_{-1}^1 |\bar{\omega}_{m+1}(t)| dt = C_m M_{m+1} \sum_{i=1}^n h_i^{m+2}. \end{aligned}$$

Учитывая, что  $\sum_{i=1}^n h_i^{m+2} \leq h_{\max}^{m+1} \sum_{i=1}^n h_i = h_{\max}^{m+1} (b - a)$ , приходим к оценке (13.19). ■

они относятся к классу формул Ньютона—Котеса. Формулы прямоугольников (13.6), трапеций (13.10) и Симпсона (13.12) отвечают использованию интерполяционных многочленов соответственно нулевой, первой и второй степени.

**2. Оценка погрешности.** Приведем теорему об оценке погрешности формулы (13.18).

**Теорема 13.3.** Пусть функция  $f$  имеет на отрезке  $[a, b]$  непрерывную производную порядка  $m + 1$ . Тогда для погрешности квадратной формулы (13.18) справедлива оценка

$$|I - I^h| \leq C_m M_{m+1} (b - a) h_{\max}^{m+1}, \quad (13.19)$$

где

$$C_m = \frac{1}{2^{m+2}(m+1)!} \int_{-1}^1 |\bar{\omega}_{m+1}(t)| dt, \quad \bar{\omega}_{m+1}(t) = \prod_{k=0}^m (t - t_k).$$

□ Представим погрешность  $R = I - I^h$  формулы (13.18) в виде

$$R = \int_a^b f(x) dx - \sum_{i=1}^n \int_{x_{i-1}}^{x_i} P_{m,i}(x) dx = \sum_{i=1}^n \int_{x_{i-1}}^{x_i} (f(x) - P_{m,i}(x)) dx.$$

Пользуясь оценкой (11.26) погрешности интерполяции, в данном случае принимающей вид

$$|f(x) - P_{m,i}(x)| \leq \frac{M_{m+1}}{(m+1)!} \left| \prod_{k=0}^m (x - z_k^{(i)}) \right|,$$

и производя замену переменной  $x = x_{i-1/2} + th_i/2$ , получаем цепочку неравенств

$$\begin{aligned} |R| &\leq \sum_{i=1}^n \int_{x_{i-1}}^{x_i} |f(x) - P_{m,i}(x)| dx \leq \sum_{i=1}^n \frac{M_{m+1}}{(m+1)!} \int_{x_{i-1}}^{x_i} \left| \prod_{k=0}^m (x - z_k^{(i)}) \right| dx = \\ &= \sum_{i=1}^n \left[ \frac{h_i}{2} \right]^{m+2} \frac{M_{m+1}}{(m+1)!} \int_{-1}^1 |\bar{\omega}_{m+1}(t)| dt = C_m M_{m+1} \sum_{i=1}^n h_i^{m+2}. \end{aligned}$$

Учитывая, что  $\sum_{i=1}^n h_i^{m+2} \leq h_{\max}^{m+1} \sum_{i=1}^n h_i = h_{\max}^{m+1} (b - a)$ , приходим к оценке (13.19). ■



$x_i$ , центральный из которых является кратным. Следовательно, эту формулу с достаточным основанием можно было бы называть и формулой кубических парабол. Закономерно, что формула Симпсона имеет четвертый порядок точности.

**3. Обусловленность квадратурных формул интерполяционного типа.** При вычислении интегралов, как правило, приходится использовать не точные значения  $f(x)$  подынтегральной функции, а приближенные значения  $f^*(x)$ . Напомним (см. § 3.1), что задача вычисления определенного интеграла от приближенно заданной функции является устойчивой. В предположении, что  $|f(x) - f^*(x)| \leq \bar{\Delta}(f^*)$  для всех  $x \in [a, b]$ , справедлива оценка

$$\Delta(I^*) = |I - I^*| = \left| \int_a^b f(x) dx - \int_a^b f^*(x) dx \right| \leq (b - a) \bar{\Delta}(f^*),$$

указывающая на то, что абсолютное число обусловленности этой задачи равно  $b - a$ , т.е. длине отрезка интегрирования.

Какова же чувствительность квадратурной формулы (13.3) к погрешностям задания функции  $f$ ? Заметим, что

$$\left| \sum_{i=0}^N A_i f(\bar{x}_i) - \sum_{i=0}^N A_i f^*(\bar{x}_i) \right| \leq \left[ \sum_{i=0}^N |A_i| \right] \bar{\Delta}(f^*).$$

Таким образом, квадратурная формула устойчива к ошибкам задания функции и ее число обусловленности  $\nu_\Delta$  равно  $\sum_{i=0}^N |A_i|$ .

Заметим, что все квадратурные формулы интерполяционного типа точны для многочленов нулевой степени и поэтому  $b - a = \int_a^b 1 \cdot dx = \sum_{i=0}^N A_i$ . Следовательно, если все веса  $A_i$  квадратурной формулы интерполяционного типа положительны, то ее число обусловленности  $\nu_\Delta$  совпадает с  $b - a$ . Чувствительность такой формулы к ошибкам адекватна чувствительности вычисляемого интеграла. Если же среди весов  $A_i$  имеются отрицательные, то  $\nu_\Delta = \sum_{i=0}^N |A_i| > \sum_{i=0}^N A_i = b - a$ .

Известно, что при больших значениях  $m$  среди весов квадратурной формулы (13.18) появляются отрицательные и значение числа обусловленности  $\nu_\Delta$  становится большим. Например, для формул Ньютона—Котеса  $\nu_\Delta \approx 3.1 (b - a)$  при  $m = 10$ ,  $\nu_\Delta \approx 8.3 (b - a)$  при  $m = 20$ ,

$\nu_{\Delta} \approx 560 (b - a)$  при  $m = 30$ . В силу плохой обусловленности эти формулы уже при  $m \geq 10$  используются весьма редко.

### § 13.3. Квадратурные формулы Гаусса

1. Построение квадратурных формул Гаусса. Из результатов предыдущего параграфа следует, что квадратурная формула  $\int_a^b f(x) dx \approx \sum_{i=0}^N A_i f(x_i)$ , построенная интегрированием интерполяционного многочлена степени  $N$  с фиксированными узлами  $x_0, x_1, \dots, x_N$ , точна для всех многочленов степени  $N$ . Однако, если имеется свобода в выборе узлов, то можно распорядиться ею так, чтобы получить формулу, точную для всех многочленов некоторой степени, превышающей  $N$ .

Поставим следующую задачу: при заданном числе  $N + 1$  узлов построить квадратурную формулу, точную для многочленов наиболее высокой степени. Формулы, удовлетворяющие этому условию, принято называть *квадратурными формулами Гаусса*. Как правило, сначала строят формулы Гаусса

$$\int_{-1}^1 f(t) dt \approx \sum_{i=0}^N a_i f(t_i) \quad (13.20)$$

для стандартного отрезка  $[-1, 1]$ . Затем с помощью замены переменной  $x = \frac{a+b}{2} + \frac{b-a}{2} t$  осуществляют переход к формулам интегрирования на произвольном отрезке:

$$\int_a^b f(x) dx \approx \frac{b-a}{2} \sum_{i=0}^N a_i f\left[\frac{a+b}{2} + \frac{b-a}{2} t_i\right]. \quad (13.21)$$

Заметим, что формула (13.20) точна для многочленов степени  $m$  тогда и только тогда, когда она точна для функций  $f(t) = 1, t, t^2, \dots, t^m$ . Это эквивалентно тому, что узлы  $t_i$  и веса  $a_i$  формулы (13.20) должны удовлетворять системе нелинейных уравнений

$$\sum_{i=0}^N a_i t_i^k = \int_{-1}^1 t^k dt = \frac{1 - (-1)^{k+1}}{k+1}, \quad k = 0, 1, \dots, m. \quad (13.22)$$

Можно показать, что система (13.22) имеет единственное решение  $a_0, \dots, a_N$ .

$a_1, \dots, a_N, t_0, t_1, \dots, t_N$  (причем  $t_i \in [-1, 1]$ ) тогда и только тогда, когда число уравнений системы совпадает с числом неизвестных, т.е. в случае  $m = 2N + 1$ .

**Пример 13.3.** Построим квадратурную формулу Гаусса (13.20) с двумя узлами.

В этом случае, т.е. при  $N = 1, m = 3$ , система (13.22) примет вид

$$\begin{aligned} a_0 + a_1 &= \int_{-1}^1 1 dt = 2, & a_0 t_0 + a_1 t_1 &= \int_{-1}^1 t dt = 0, \\ a_0 t_0^2 + a_1 t_1^2 &= \int_{-1}^1 t^2 dt = \frac{2}{3}, & a_0 t_0^3 + a_1 t_1^3 &= \int_{-1}^1 t^3 dt = 0. \end{aligned}$$

Решая ее, находим значения  $a_0 = a_1 = 1, t_0 = -\frac{1}{\sqrt{3}}, t_1 = \frac{1}{\sqrt{3}}$ . Таким образом, получаем квадратурную формулу Гаусса

$$\int_{-1}^1 f(t) dt \approx f\left[-\frac{1}{\sqrt{3}}\right] + f\left[\frac{1}{\sqrt{3}}\right],$$

точную для многочленов третьей степени.

Для квадратурной формулы Гаусса справедлива следующая оценка погрешности:

$$|R| \leq \alpha_N M_{2N+2} (b-a)^{2N+3}.$$

Входящий в нее коэффициент  $\alpha_N = \frac{[(N+1)!]^4}{(2N+3)[(2N+2)!]^3}$  очень быстро убывает с ростом  $N$ . Приведем, например, несколько первых его значений:  $\alpha_0 \approx 4 \cdot 10^{-2}$ ,  $\alpha_1 \approx 2 \cdot 10^{-4}$ ,  $\alpha_2 \approx 5 \cdot 10^{-7}$ ,  $\alpha_3 \approx 6 \cdot 10^{-10}$ ,  $\alpha_4 \approx 4 \cdot 10^{-13}$ .

Можно было бы разбить отрезок интегрирования на частичные отрезки и исходя из формулы Гаусса построить составную формулу, имеющую порядок точности, равный  $2N + 2$ . Однако при интегрировании достаточно гладких функций в этом нет необходимости, так как уже при небольшом числе узлов ( $4 \lesssim N \lesssim 10$ ) формула Гаусса обеспечивает очень высокую точность. На практике используются и формулы с десятками и сотнями узлов.

**2. Узлы и веса квадратурной формулы Гаусса.** Приведем значения узлов и весов квадратурной формулы Гаусса с числом узлов от 1 до 6 (табл. 13.2):

Т а б л и ц а 13.2

Число Узлы и веса	1	2	3
$t_0$	0.00000000000	-0.5773502692	-0.7745966692
$a_0$	2.00000000000	1.00000000000	0.55555555556
$t_1$		0.5773502692	0.00000000000
$a_1$		1.00000000000	0.88888888888
$t_2$			0.7745966692
$a_2$			0.55555555556

Число Узлы и веса	4	5	6
$t_0$	-0.8611363115	-0.9061798459	-0.9324695142
$a_0$	0.3478548451	0.2369268851	0.1713244924
$t_1$	-0.3399810436	-0.5384693101	-0.6612093864
$a_1$	0.6521451549	0.4786286705	0.3607615730
$t_2$	0.3399810436	0.00000000000	-0.2386191861
$a_2$	0.6521451549	0.56888888888	0.4679139346
$t_3$	0.8611363115	0.5384693101	0.2386191861
$a_3$	0.3478548451	0.4786286705	0.4679139346
$t_4$		0.9061798459	0.6612093864
$a_4$		0.2369268851	0.3607615730
$t_5$			0.9324695142
$a_5$			0.1713244924

**Пример 13.4.** Найдем значение интеграла  $\int_0^1 e^{-x^2} dx$ , используя квадратурную формулу Гаусса с двумя, тремя и четырьмя узлами.

В данном случае  $a = 0$ ,  $b = 1$ ,  $f(x) = e^{-x^2}$  и формула (13.21) принимает вид

$$I = \int_0^1 e^{-x^2} dx \approx I_N = \frac{1}{2} \sum_{i=0}^N a_i e^{-(0.5+0.5t_i)^2}$$

Взяв из табл. 13.2 значения узлов  $t_i$  и весов  $a_i$  при  $N = 1, 2, 3$ , получим следующие приближения:

$$I \approx I_1 = \frac{1}{2} (e^{-(0.211324865)^2} + e^{-(0.788675135)^2}) \approx 0.7465946885;$$

$$\begin{aligned}
I \approx I_2 &= \frac{1}{2} (0.5555555556 \cdot e^{-(0.1127011665)^2} + 0.8888888888 \cdot e^{-0.25} + \\
&+ 0.5555555556 \cdot e^{-(0.887298335)^2}) \approx 0.7468145842; \\
I \approx I_3 &= \frac{1}{2} (0.3478548451 \cdot e^{-(0.069431844)^2} + 0.6521451549 \cdot e^{-(0.330009478)^2} + \\
&+ 0.6521451549 \cdot e^{-(0.669990522)^2} + 0.3478548451 \cdot e^{-(0.930568156)^2}) \approx \\
&\approx 0.7468244681.
\end{aligned}$$

Эти значения содержат такие абсолютные погрешности:  $\Delta(I_1) \approx 2 \cdot 10^{-4}$ ,  $\Delta(I_2) \approx 10^{-5}$ ,  $\Delta(I_3) \approx 3 \cdot 10^{-7}$ . Для сравнения укажем, что значение того же интеграла, полученное в примере 13.2 по формуле прямоугольников с 10 узлами, имеет абсолютную погрешность примерно  $3 \cdot 10^{-4}$ , а по формуле Симпсона с 21 узлом — абсолютную погрешность примерно  $5 \cdot 10^{-8}$ .

**3. Обусловленность квадратурных формул Гаусса.** Квадратурные формулы Гаусса обладают еще одним замечательным свойством: их весовые коэффициенты всегда положительны. Это свойство (как следует из рассуждений предыдущего параграфа) гарантирует хорошую обусловленность квадратурной формулы. Более того, число обусловленности равно  $b - a$  и не зависит от числа узлов. Это позволяет применять на практике квадратурные формулы Гаусса с числом узлов, достигающим сотен.

### § 13.4. Апостериорные оценки погрешности.

#### Понятие об адаптивных процедурах численного интегрирования

Применение неравенств типа (13.13), (13.14), (13.15), (13.19) для априорной оценки погрешности квадратурных формул в большинстве случаев оказывается неэффективным или вообще невозможным. Это связано как с трудностями оценивания производных подынтегральной функции  $f$ , так и с тем, что получаемые оценки, как правило, бывают сильно завышенными. На практике обычно используются иные подходы к оценке погрешности, позволяющие строить процедуры численного интегрирования с автоматическим выбором шага.

**1. Главный член погрешности.** Пусть  $I^h$  — приближенное значение интеграла  $I = \int_a^b f(x) dx$ , вычисленное по некоторой квадратурной формуле и использующее разбиение отрезка  $[a, b]$  на элементарные отрезки длины  $h$ . Предположим, что для погрешности этой формулы справедливо представление<sup>1</sup>

<sup>1</sup> Напомним, что запись  $\varphi(h) = o(h^k)$  (читается " $\varphi(h)$  есть  $o$  малое от  $h^k$ ") означает, что  $\varphi(h)/h^k \rightarrow 0$  при  $h \rightarrow 0$ .

$$I - I^h = Ch^k + o(h^k), \quad (13.23)$$

где  $C \neq 0$  и  $k > 0$  — величины, не зависящие от  $h$ . Тогда величина  $Ch^k$  называется *главным членом погрешности* квадратурной формулы.

Заметим, что из неравенства (13.23) следует справедливость оценки  $|I - I^h| \leq \bar{C}h^k$  с некоторой постоянной  $\bar{C} > |C|$ . Поэтому число  $k$  представляет собой не что иное как порядок точности соответствующей квадратурной формулы.

Если подынтегральная функция  $f$  достаточно гладкая, то для каждой из составных квадратурных формул

$$I \approx I^h = \sum_{i=1}^n h \sum_{j=0}^m a_j f(x_{i-1/2} + t_j h/2) \quad (13.24)$$

существует главный член погрешности. Приведем без доказательства соответствующий результат.

**Т е о р е м а 13.4.** Пусть  $\sum_{j=0}^m a_j = 1$  и  $k$  — минимальное среди натуральных чисел, для которых величина

$$\sigma_k = \frac{1}{2} \int_{-1}^1 t^k dt - \sum_{j=0}^m a_j t_j^k$$

отлична от нуля. Если функция  $f$  непрерывно дифференцируема  $k$  раз на отрезке  $[a, b]$ , то для погрешности квадратурной формулы (13.24) справедливо представление (13.23), в котором

$$C = \frac{\sigma_k}{2^k k!} \int_a^b f^{(k)}(x) dx = \frac{\sigma_k}{2^k k!} (f^{(k-1)}(b) - f^{(k-1)}(a)).$$

**С л е д с т в и е 1.** Если функция  $f$  дважды непрерывно дифференцируема на отрезке  $[a, b]$ , то для погрешностей составных квадратурных формул прямоугольников и трапеций справедливы следующие представления:

$$I - I_{\text{пр}}^h = C_{\text{пр}} h^2 + o(h^2), \quad C_{\text{пр}} = \frac{1}{24} \int_a^b f''(x) dx, \quad (13.25)$$

$$I - I_{\text{тр}}^h = C_{\text{тр}} h^2 + o(h^2), \quad C_{\text{тр}} = -\frac{1}{12} \int_a^b f''(x) dx. \quad (13.26)$$

**С л е д с т в и е 2.** Если функция  $f$  четырежды непрерывно дифференцируема на отрезке  $[a, b]$ , то для погрешности составной квадратурной формулы Симпсона справедливо представление

$$I - I_c^h = C_c h^4 + o(h^4), \quad C_c = -\frac{1}{2880} \int_a^b f^{(4)}(x) dx. \quad (13.27)$$

В силу предположения (13.23) для погрешности квадратурной формулы при достаточно малом  $h$  справедливо приближенное равенство

$$I - I^h \approx Ch^k. \quad (13.28)$$

Несмотря на элементарный характер формулы (13.28), она позволяет сделать ряд важных выводов. Первый из них состоит в том, что уменьшение шага  $h$  в  $M$  раз приводит к уменьшению погрешности квадратурной формулы примерно в  $M^k$  раз. Действительно, при  $h_1 = h/M$  имеем

$$I - I^{h_1} \approx Ch_1^k = \frac{1}{M^k} Ch^k \approx \frac{1}{M^k} (I - I^h).$$

В частности, уменьшение шага  $h$  в два раза приводит к уменьшению погрешности примерно в  $2^k$  раз:

$$I - I^{h/2} \approx \frac{1}{2^k} Ch^k \approx \frac{1}{2^k} (I - I^h). \quad (13.29)$$

**2. Правило Рунге практической оценки погрешности.** Как следует из теоремы 13.4, главный член погрешности квадратурной формулы интерполяционного типа имеет вид

$$\frac{\sigma_k}{2^k k!} \int_a^b f^{(k)}(x) dx h^k = \frac{\sigma_k}{2^k k!} (f^{(k-1)}(b) - f^{(k-1)}(a)) h^k.$$

Непосредственное использование этой формулы для оценки погрешности  $I - I^h$  неудобно, так как требует вычисления производных функций  $f$ . В более сложных ситуациях выражение для главного члена погрешности может оказаться существенно более громоздким. Поэтому в вычислительной практике часто применяются методы оценки погрешности, не использующие явное выражение для главного члена.

Вычитая из равенства (13.28) равенство (13.29), получим

$$I^{h/2} - I^h \approx \frac{1}{2^k} Ch^k (2^k - 1).$$

Учитывая приближенное равенство (13.29), приходим к следующей приближенной формуле:

$$I - I^{h/2} \approx \frac{I^{h/2} - I^h}{2^k - 1}. \quad (13.30)$$

Использование этой формулы для апостериорной оценки погрешности значения  $I^h$  принято называть *правилом Рунге* (или *правилом двойного пересчета*).

**З а м е ч а н и е 1.** Так как  $I - I^h \approx 2^k(I - I^{h/2})$ , то из (13.30) следует формула  $I - I^h \approx \frac{2^k(I^{h/2} - I^h)}{2^k - 1}$ , которую можно было бы использовать для приближенной оценки погрешности значения  $I^h$ . Как правило, этого не делают, поскольку среди двух вычисляемых значений интеграла  $I^h$  и  $I^{h/2}$  второе является более точным и имеет смысл оценивать именно его погрешность.

**З а м е ч а н и е 2.** Заменой  $h$  на  $2h$  формула (13.30) приводится к следующему виду:

$$I - I^h \approx \frac{I^h - I^{2h}}{2^k - 1} \quad (13.31)$$

Для формул прямоугольников и трапеций  $k = 2$  (см. (13.25) и (13.26)), а для формулы Симпсона  $k = 4$  (см. (13.27)). Поэтому для этих квадратурных формул равенство (13.31) принимает следующий вид:

$$I - I_{\text{пр}}^h \approx \frac{1}{3} (I_{\text{пр}}^h - I_{\text{пр}}^{2h}), \quad (13.32)$$

$$I - I_{\text{тр}}^h \approx \frac{1}{3} (I_{\text{тр}}^h - I_{\text{тр}}^{2h}), \quad (13.33)$$

$$I - I_{\text{С}}^h \approx \frac{1}{15} (I_{\text{С}}^h - I_{\text{С}}^{2h}), \quad (13.34)$$

**Пример 13.5.** Применяя правило Рунге, оценим погрешность приближенных значений  $I_{\text{пр}}^h = 0.74713088$ ,  $I_{\text{тр}}^h = 0.74621079$ ,  $I_{\text{С}}^h = 0.74628418$ , полученных в примере 13.2 при вычислении интеграла  $I = \int_0^1 e^{-x^2} dx$  и использующих формулы прямоугольников, трапеций и Симпсона с шагом  $h = 0.1$ .

Вычислим приближенные значения интеграла по указанным квадратурным формулам с удвоенным значением шага. В результате получим  $I_{\text{пр}}^{2h} = 0.74805326$ ,  $I_{\text{тр}}^{2h} = 0.74436832$ ,  $I_{\text{С}}^{2h} = 0.74682495$ .

Применяя теперь формулы (13.32) — (13.34), находим



$$I - I_{\text{пр}}^h \approx \frac{1}{3} (0.74713088 - 0.74805326) \approx -3 \cdot 10^{-4}, \quad I - I_{\text{тр}}^h \approx \frac{1}{3} (0.74621079 - \\ - 0.74436832) \approx 6 \cdot 10^{-4}, \quad I - I_{\text{с}}^h \approx \frac{1}{15} (0.74682418 - 0.74682495) \approx -5 \cdot 10^{-8}.$$

Естественно, что кроме правила Рунге существуют и другие способы апостериорной оценки погрешности. Например, можно использовать значения  $I_{\text{пр}}^h$  и  $I_{\text{тр}}^h$ , вычисленные по формулам прямоугольников и трапеций с одним и тем же шагом, для практической оценки погрешности каждого из этих значений. Действительно, в равенствах (13.25), (13.26)  $C_{\text{тр}} = -2 C_{\text{пр}}$ . Поэтому

$$I_{\text{тр}}^h - I_{\text{пр}}^h = (C_{\text{пр}} - C_{\text{тр}})h^2 + o(h^2) \approx 3C_{\text{пр}}h^2.$$

Отсюда следует, что

$$I - I_{\text{пр}}^h \approx \frac{1}{3} (I_{\text{тр}}^h - I_{\text{пр}}^h), \quad (13.35)$$

$$I - I_{\text{тр}}^h \approx -\frac{2}{3} (I_{\text{тр}}^h - I_{\text{пр}}^h). \quad (13.36)$$

**Пример 13.6.** Применяя формулы (13.35), (13.36), оценим погрешности значений  $I_{\text{пр}}^h = 0.74713088$ ,  $I_{\text{тр}}^h = 0.74621079$ , являющихся приближениями к значению интеграла  $I = \int_0^1 e^{-x^2} dx$  (см. пример 13.2).

Имеем  $I - I_{\text{пр}}^h \approx \frac{1}{3} (0.74621079 - 0.74713088) \approx -3 \cdot 10^{-4}$ ,  $I - I_{\text{тр}}^h \approx -2(-3 \cdot 10^{-4}) = 6 \cdot 10^{-4}$ . Отметим, что полученные оценки совпадают с соответствующими оценками из примера 13.5.

Наличие некоторого правила получения апостериорной оценки погрешности позволяет строить процедуры вычисления интеграла  $I$  с заданной точностью  $\varepsilon$ , достигаемой последовательным дроблением шага интегрирования. Простейшая процедура такого типа состоит в последовательном вычислении значений  $I^{h_i}$  и соответствующих апостериорных оценок погрешности  $\varepsilon_i$  (например, по правилу Рунге) для  $h_i = h_0/2^i$ , где  $h_0$  — начальное значение шага,  $i = 1, 2, \dots$ . Вычисления прекращаются тогда, когда при некотором  $i$  оказывается  $|\varepsilon_i| < \varepsilon$  (требуемая точность достигнута) либо тогда, когда величина  $|\varepsilon_i|$  начинает возрастать (точность не может быть достигнута из-за влияния вычислительной погрешности).

**Пример 13.7.** Найдем значение интеграла  $I = \int_0^1 e^{-x^2} dx$  с точностью  $\varepsilon = 10^{-4}$ , используя формулу трапеций и применяя процедуру последовательного дробления шага интегрирования, описанную выше.

Возьмем  $h_0 = 0.2$ . Значения  $I^{h_0} = 0.74436832$ ,  $I^{h_1} = 0.74621079$  (где  $h_1 = h_0/2 = 0.1$ ) и  $\varepsilon_1 = 6 \cdot 10^{-4}$  были уже получены (см. пример 13.5). Так как  $|\varepsilon_1| > \varepsilon$ , то уменьшаем шаг вдвое:  $h_2 = h_1/2 = 0.05$  и вычисляем  $I^{h_2} = 0.74667084$ ,  $\varepsilon_2 = \frac{1}{3} (I^{h_2} - I^{h_1}) = \frac{1}{3} (0.74667084 - 0.74621079) \approx 1.5 \cdot 10^{-4}$ . Так как  $|\varepsilon_2| > \varepsilon$ , то снова дробим шаг:  $h_3 = h_2/2 = 0.025$ , вычисляем  $I^{h_3} = 0.74678581$ ,  $\varepsilon_3 = \frac{1}{3} (I^{h_3} - I^{h_2}) = \frac{1}{3} (0.74678581 - 0.74667084) \approx 4 \cdot 10^{-5}$ . Поскольку  $|\varepsilon_3| < \varepsilon$ , требуемая точность достигнута и с учетом округления получаем  $I = 0.7468 \pm 0.0001$ .

**3. Экстраполяция Ричардсона.** Наличие приближенного равенства  $I - I^{h/2} \approx \frac{1}{2^k} Ch^k$  и формулы  $\frac{Ch^k}{2^k} \approx \frac{I^{h/2} - I^h}{2^k - 1}$  позволяют получить уточненное значение интеграла

$$I \approx I^{h/2} + \frac{1}{2^k - 1} (I^{h/2} - I^h). \quad (13.37)$$

Таким образом, квадратурная формула  $I^h$  порождает новую квадратурную формулу (13.37), имеющую более высокий порядок точности. Если этот порядок известен, то процесс уточнения можно продолжить.

Предположим, например, что для погрешности квадратурной формулы справедливо представление

$$I - I^h = C_1 h^{k_1} + C_2 h^{k_2} + \dots + C_N h^{k_N} + o(h^{k_N}) \quad (13.38)$$

при всех  $N = 1, 2, \dots$ , причем  $0 < k_1 < k_2 < \dots < k_N < \dots$ . В этом случае формула (13.37) приводит к следующему методу уточнения, который называют также *методом экстраполяции Ричардсона*<sup>1</sup>. Пусть шаг  $h$  измельчается по правилу  $h_j = h_{j-1}/2$ ,  $j = 1, 2, \dots, N$ . Сначала полагают  $I_0^h = I^h$ . Для вычисления всех последующих приближений используют рекуррентное соотношение

<sup>1</sup> Арчибалд Рид Ричардсон (1881 — 1954) — английский математик.

$$I_N^h = I_{N-1}^{h/2} + \frac{1}{2^N - 1} (I_{N-1}^{h/2} - I_{N-1}^h), \quad N = 1, 2, \dots$$

**Пример 13.8.** Так как для формулы трапеций равенство (13.38) имеет место, причем  $k_1 = 2$ ,  $k_2 = 4$ , ...,  $k_N = 2N$ , то к ней можно применить экстраполяцию Ричардсона. В результате получается так называемый *метод Ромберга*. Существуют стандартные программы вычисления интегралов методом Ромберга. Правда, следует отметить, что эффективность этого метода не велика. Как правило, лучший результат дает применение квадратурных формул Гаусса или рассматриваемых ниже адаптивных процедур численного интегрирования.

**З а м е ч а н и е.** Первый же шаг метода Ромберга приводит к уточнению квадратурной формулы трапеций, совпадающему с формулой Симпсона. Действительно,

$$\begin{aligned} I_{\text{тр}}^{h/2} + \frac{1}{3} (I_{\text{тр}}^{h/2} - I_{\text{тр}}^h) &= \frac{4}{3} I_{\text{тр}}^{h/2} - \frac{1}{3} I_{\text{тр}}^h = \\ &= \frac{2h}{3} \left[ \frac{f_0 + f_n}{2} + \sum_{i=1}^{2n-1} f_{i/2} \right] - \frac{h}{3} \left[ \frac{f_0 + f_n}{2} + \sum_{i=1}^{n-1} f_i \right] = \\ &= \frac{h}{6} (f_0 + f_n + 4 \sum_{i=1}^n f_{i-1/2} + 2 \sum_{i=1}^{n-1} f_i) = I_c^h. \end{aligned}$$

**4. Адаптивные процедуры численного интегрирования.** До сих пор нам было удобнее рассматривать методы численного интегрирования с постоянным шагом. Однако они обладают значительно меньшей эффективностью и используются в вычислительной практике существенно реже, чем методы с переменным шагом. Объясняется это тем, что, равномерно распределяя узлы по отрезку интегрирования, мы полностью игнорируем особенности поведения подынтегральной функции. В то же время интуитивно ясно, что на участках плавного изменения функции достаточно поместить сравнительно небольшое число узлов, разместив значительно большее их число на участках резкого изменения функции. Распределение узлов интегрирования в соответствии с характером поведения подынтегральной функции часто позволяет при том же общем числе узлов получить значительно более высокую точность. Тем не менее выбор соответствующего неравномерного распределения узлов интегрирования является очень сложной задачей и вряд ли мог быть широко использован на практике, если бы для решения этой задачи не удалось привлечь ЭВМ.

Современные процедуры численного интегрирования (*адаптивные квадратурные программы*) используют некоторый алгоритм автомати-

ческого распределения узлов интегрирования. Пользователь такой программы задает отрезок  $[a, b]$ , правило вычисления функции  $f$  и требуемую точность  $\varepsilon > 0$ . Программа стремится, используя по возможности минимальное число узлов интегрирования, распределить их так, чтобы найденное значение  $I^h = \sum_{i=1}^n I_i^h$  удовлетворяло неравенству

$$|I^h - \int_a^b f(x)dx| < \varepsilon. \quad (13.39)$$

Здесь  $I_i^h$  — приближенное значение интеграла  $I_i = \int_{x_{i-1}}^{x_i} f(x)dx$ , вычисляемое по некоторой формуле.

Типичная программа разбивает исходный отрезок  $[a, b]$  на элементарные отрезки  $[x_{i-1}, x_i]$  так, чтобы для погрешностей  $R_i = I_i - I_i^h$  выполнялось неравенство

$$\sum_{i=1}^n |R_i| < \varepsilon. \quad (13.40)$$

При этом каждый из элементарных отрезков получается, как правило, делением пополам одного из отрезков, найденных на более раннем шаге алгоритма. Заметим, что неравенство (13.40) выполняется, если каждая из погрешностей  $R_i$  удовлетворяет условию  $|R_i| < h_i \varepsilon / (b - a)$ . Действительно, тогда  $|I - I^h| = \left| \sum_{i=1}^n (I_i - I_i^h) \right| \leq \sum_{i=1}^n |R_i| < \frac{\varepsilon}{b-a} \sum_{i=1}^n h_i = \varepsilon$ .

Рассмотрим, например, одну из простейших адаптивных процедур, основанную на формуле трапеций

$$I_i \approx I_{\text{тр},i}^h = \frac{h_i}{2} (f_{i-1} + f_i) \quad (13.41)$$

и использующую для контроля точности составную формулу трапеций с шагом  $h_i/2$ :

$$I_i \approx I_i^h = \frac{h_i}{4} (f_{i-1} + 2f_{i-1/2} + f_i). \quad (13.42)$$

Заметим, что если значение  $I_{\text{тр},i}^h$  уже найдено, то для нахождения значения  $I_i^h$  требуется лишь одно дополнительное вычисление функции  $f$  в точке  $x_{i-1/2}$ .

Можно показать, что для оценки погрешностей квадратурных формул интерполяционного типа на элементарных отрезках правило Рунге сохраняет силу. Поэтому погрешность приближенного значения  $I_i^h$  можно оценить по формуле

$$R_i \approx \varepsilon_i = \frac{1}{3} (I_i^h - I_{\text{тр},i}^h). \quad (13.43)$$

В рассматриваемой адаптивной процедуре последовательно выбирают точки  $x_i$  и вычисляют значения

$$S_i = \sum_{j=1}^i I_j^h \approx \int_a^{x_i} f(x) dx \quad (i = 1, 2, \dots, n),$$

последнее из которых  $S_n$  совпадает с  $I^h$  и принимается за приближенное значение интеграла  $I$ . Перед началом работы полагают  $S_0 = 0$ ,  $x_0 = a$  и задают некоторое начальное значение шага  $h_1$ .

Опишем  $i$ -й шаг процедуры в предположении, что значение  $S_{i-1}$  уже найдено и очередное значение шага  $h_i$  определено.

1°. По формулам (13.41) — (13.43) вычисляют значения  $I_{\text{тр},i}^h$ ,  $I_i^h$ ,  $\varepsilon_i$ .

2°. Если  $|\varepsilon_i| > h_i \varepsilon / (b - a)$ , то шаг  $h_i$  уменьшают в 2 раза и повторяются вычисления п. 1°.

3°. После того как очередное дробление шага приводит к выполнению условия  $|\varepsilon_i| \leq h_i \varepsilon / (b - a)$ , вычисляют значения  $x_i = x_{i-1} + h_i$ ,  $S_i = S_{i-1} + I_i^h$ .

4°. Если  $x_i + h_i > b$ , то полагают  $h_{i+1} = b - x_i$ . В противном случае полагают  $h_{i+1} = h_i$ . На этом  $i$ -й шаг завершается.

**З а м е ч а н и е 1.** В некоторых адаптивных процедурах при выполнении условия типа  $|\varepsilon_i| \leq h_i \varepsilon / (b - a)$  очередное значение шага удваивается:  $h_{i+1} = 2 h_i$ . Таким образом, шаг интегрирования в зависимости от характера поведения подынтегральной функции может не только измельчаться, но и укрупняться.

**З а м е ч а н и е 2.** Известно [9], что при оптимальном распределении узлов интегрирования модули погрешностей, приходящихся на элементарные отрезки интегрирования, должны быть примерно одинаковыми. Распределение узлов, полученное с помощью адаптивных процедур, как правило, не является таковым. Однако для большинства функций оно является вполне удовлетворительным.

## § 13.5. Вычисление интегралов в нерегулярных случаях

Нередко приходится вычислять интегралы

$$\int_a^b F(x) dx \quad (13.44)$$

от функций, имеющих те или иные особенности. Например, сама функция  $F$  (или ее производная некоторого порядка) имеет участки резкого изменения, точки разрыва или является неограниченной. Такие функции плохо аппроксимируются многочленами и поэтому для вычисления соответствующих интегралов может оказаться неэффективным непосредственное применение стандартных квадратурных формул, рассчитанных на возможность кусочно-многочленной аппроксимации функции  $F$ . Случай, когда в интеграле (13.44) промежуток интегрирования бесконечен, также требует специального рассмотрения.

**Пример 13.9.** Функция  $\frac{1}{\sqrt{x}} e^{-x^2}$  имеет особенность в точке  $x = 0$ . Попробуем

применить для вычисления интеграла

$$I = \int_0^1 \frac{1}{\sqrt{x}} e^{-x^2} dx \approx 1.689677 \quad (13.45)$$

формулу прямоугольников с постоянным шагом:

$$I \approx I_{\text{пр}}^h = \sum_{i=1}^n \frac{1}{\sqrt{x_{i-1/2}}} e^{-x_{i-1/2}^2} h. \quad (13.46)$$

Результаты вычислений для нескольких значений шага  $h$  приведены в табл. 13.3. Заметим, что значения  $I_{\text{пр}}^h$  сходятся к  $I$  очень медленно. Теоретический анализ погрешности показывает, что она убывает пропорционально лишь  $h^{1/2}$ , а не  $h^2$ , как в регулярном случае.

Т а б л и ц а 13.3

$h$	$I_{\text{пр}}^h$	$I - I_{\text{пр}}^h$
0.200	1.420	$2.7 \cdot 10^{-1}$
0.100	1.499	$1.9 \cdot 10^{-1}$
0.050	1.555	$1.4 \cdot 10^{-1}$
0.025	1.594	$9.6 \cdot 10^{-2}$

Укажем на некоторые подходы к вычислению интегралов в нерегулярных случаях, позволяющие учесть особенности поведения функции  $F$  и благодаря этому значительно сократить затраты машинного времени или достичь большей точности.

**1. Разбиение промежутка интегрирования на части.** Пусть подынтегральная функция  $F$  является кусочно-гладкой и  $c_1 < c_2 < \dots < c_p$  — известные точки разрыва функции  $F$  либо ее производных. В этом случае имеет смысл представить интеграл (13.44) в виде суммы:

$$\int_a^b F(x)dx = \int_a^{c_1} F(x)dx + \int_{c_1}^{c_2} F(x)dx + \dots + \int_{c_p}^b F(x)dx. \quad (13.47)$$

Вычисление каждого из входящих в сумму (13.47) интегралов представляет собой стандартную задачу, так как на каждом из частичных отрезков  $[a, c_1]$ ,  $[c_1, c_2]$ , ...,  $[c_p, b]$  подынтегральная функция является гладкой.

Разбиение промежутка интегрирования на части может оказаться полезным приемом и в других случаях, например тогда, когда имеет смысл на разных частях применять различные квадратурные формулы. Другой пример дает стандартный прием вычисления несобственных

интегралов вида  $\int_a^\infty F(x)dx$ . Если требуется вычислить такой интеграл с точностью  $\epsilon > 0$ , то его представляют в виде суммы:

$$\int_a^\infty F(x)dx = \int_a^b F(x)dx + \int_b^\infty F(x)dx. \quad \text{Затем благодаря выбору достаточно}$$

большого  $b$  добиваются выполнения неравенства  $|\int_b^\infty F(x)dx| < \epsilon/2$  и

вычисляют интеграл  $\int_a^b F(x)dx$  с точностью  $\epsilon/2$ .

**2. Выделение веса.** В некоторых случаях подынтегральная функция допускает разложение на два сомножителя:  $F(x) = \rho(x) \cdot f(x)$ , где функция  $\rho(x)$  является достаточно простой и имеет те же особенности, что и  $F(x)$ , а  $f(x)$  — гладкая функция. Тогда имеет смысл рассматривать интеграл (13.44) в виде

$$I = \int_a^b \rho(x)f(x)dx. \quad (13.48)$$

Здесь функция  $\rho(x)$  называется *весовой функцией* (или *весом*). При построении численных методов вычисления интеграла (13.48) весовая

функция считается фиксированной. В то же время  $f(x)$  может быть произвольной достаточно гладкой функцией.

Примерами весовых функций могут служить постоянный вес  $\rho(x) \equiv 1$ , весовые функции Якоби  $\rho(x) = (x-a)^\alpha(b-a)^\beta$  ( $a < x < b$ ), Лагерра<sup>1</sup>  $\rho(x) = x^\alpha e^{-x}$  ( $0 < x < \infty$ ) и Эрмита  $\rho(x) = e^{-x^2}$  ( $-\infty < x < \infty$ ), соответствующие интегралам вида  $\int_a^b f(x)dx$ ,  $\int_a^b (x-a)^\alpha(x-b)^\beta f(x)dx$ ,  $\int_0^\infty x^\alpha e^{-x} f(x)dx$ ,  $\int_{-\infty}^\infty e^{-x^2} f(x)dx$ .

Методы приближенного вычисления интегралов, рассмотренные в предыдущих параграфах, применимы и к задаче вычисления интегралов с весом.

Пусть  $P_{m,i}$  — интерполяционные многочлены (13.17). Приближенная замена интеграла (13.48) суммой:

$$I^h = \sum_{i=1}^n \int_{x_{i-1}}^{x_i} \rho(x) P_{m,i}(x) dx$$

приводит к следующей квадратурной формуле интерполяционного типа:

$$I \approx I^h = \sum_{i=1}^n h_i \sum_{j=0}^m a_{ij} f(x_{i-1/2} + t_j h_i/2). \quad (13.49)$$

Здесь коэффициенты  $a_{ij}$  вычисляются по формуле

$$a_{ij} = \frac{1}{2} \int_{-1}^1 \rho(x_{i-1/2} + th_i/2) \prod_{\substack{k=0 \\ k \neq j}}^m \frac{t - t_k}{t_j - t_k} dt.$$

Если функция  $f$  имеет на отрезке  $[a, b]$  непрерывную производную порядка  $m+1$ , то для погрешности формулы (13.49) верна оценка

$$|I - I^h| \leq C_m M_{m+1} \int_a^b |\rho(x)| dx h_{\max}^{m+1}.$$

**Пример 13.10.** Выведем аналог формулы прямоугольников с постоянным шагом для вычисления интеграла

<sup>1</sup> Эдмунд Никола Лагерр (1834 — 1886) — французский математик.



$$I = \int_{-1}^1 \frac{1}{\sqrt{x}} f(x) dx \quad (13.50)$$

Заменяя функцию  $f$  на элементарном отрезке  $[x_{i-1}, x_i]$  постоянной  $f_{i-1/2}$  и учитывая, что

$$\int_{x_{i-1}}^{x_i} \frac{1}{\sqrt{x}} f(x) dx \approx \int_{x_{i-1}}^{x_i} \frac{1}{\sqrt{x}} f_{i-1/2} dx = \frac{2h}{\sqrt{x_{i-1}} + \sqrt{x_i}} f_{i-1/2},$$

получим следующую квадратурную формулу:

$$\int_0^1 \frac{1}{\sqrt{x}} f(x) dx \approx I^h = h \sum_{i=1}^n \frac{2}{\sqrt{x_{i-1}} + \sqrt{x_i}} f_{i-1/2} \quad (13.51)$$

**Пример 13.11.** Применим квадратурную формулу (13.51) для вычисления интеграла (13.45) при тех же значениях шага, что и в примере 13.9.

В рассматриваемом случае формула (13.51) принимает вид

$$\int_0^1 \frac{1}{\sqrt{x}} e^{-x^2} dx \approx h \sum_{i=1}^n \frac{2}{\sqrt{x_{i-1}} + \sqrt{x_i}} e^{-x_{i-1/2}^2}. \quad (13.52)$$

Полученные с ее помощью результаты приведены в табл. 13.4. Сравнение с результатами примера 13.9 показывает, что для вычисления интеграла (13.45) формула (13.52) имеет безусловное преимущество перед формулой прямоугольников (13.46).

Т а б л и ц а 13.4

$h$	$I^h$	$I - I^h$
0.200	1.686276	$3.4 \cdot 10^{-3}$
0.100	1.688958	$7.2 \cdot 10^{-4}$
0.050	1.689521	$1.6 \cdot 10^{-4}$
0.025	1.689642	$3.5 \cdot 10^{-5}$

Для вычисления интегралов (13.48) применяют и квадратурные формулы Гаусса  $\int_a^b \rho(x) f(x) dx \approx \sum_{i=1}^n A_i f(x_i)$ , точные для многочленов наиболее высокой степени. Они строятся аналогично тому, как было сделано в случае постоянного веса  $\rho(x) \equiv 1$  (см. § 13.4).

**Пример 13.12.** Для вычисления интеграла (13.50) построим квадратурную формулу Гаусса с одним узлом:

$$\int_0^1 \frac{1}{\sqrt{x}} f(x) dx \approx c_1 f(x_1). \quad (13.53)$$

Потребуем, чтобы формула (13.53) была точна для многочленов первой степени. Это эквивалентно выполнению равенств  $2 = \int_0^1 \frac{1}{\sqrt{x}} dx = c_1$ ,  $\frac{2}{3} = \int_0^1 \frac{x}{\sqrt{x}} dx = c_1 x_1$ . Таким образом  $c_1 = 2$ ,  $x_1 = 1/3$  и формула (13.53) принимает вид

$$\int_0^1 \frac{1}{\sqrt{x}} f(x) dx \approx 2f\left[\frac{1}{3}\right]. \quad (13.54)$$

Хотя формула (13.54) и кажется примитивной, применяя ее для вычисления интеграла (13.45), получаем значение  $I \approx 1.789679$ , абсолютная погрешность которого равна 0.1 и практически совпадает с погрешностью значения, найденного в примере 13.9 по формуле прямоугольников с шагом  $h = 0.025$ . Замечательно то, что формула Гаусса (13.54) достигает точности  $\varepsilon = 0.1$  при использовании только одного вычисления значения функции  $f(x) = e^{-x^2}$ . В то же время формула (13.46) для достижения той же точности требует вычисления 40 значений функции.

**3. Формула Эрмита.** Для вычисления интегралов вида  $\int_{-1}^1 \frac{f(x)}{\sqrt{1-x^2}} dx$ ,

т.е. в случае  $\rho(x) = 1/\sqrt{1-x^2}$ ,  $a = -1$ ,  $b = 1$ , используют квадратурную формулу Гаусса

$$\int_{-1}^1 \frac{f(x)}{\sqrt{1-x^2}} dx \approx \frac{\pi}{n} \sum_{i=1}^n f(x_i),$$

называемую *формулой Эрмита*. Узлами этой формулы являются нули многочлена Чебышева  $T_n(x)$ , т.е. числа  $x_i = \cos \frac{(2i-1)\pi}{2n}$ ,  $1 \leq i \leq n$ .

**4. Интегрирование быстро осциллирующих функций.** В задачах радиотехники часто встречается проблема вычисления интегралов вида<sup>1</sup>

$$\int_a^b f(x) e^{i\omega x} dx = \int_a^b f(x) \cos \omega x dx + i \int_a^b f(x) \sin \omega x dx. \quad (13.55)$$

<sup>1</sup> Например,  $F(x) = f(x)e^{i\omega x}$  отвечает несущему высокочастотному колебанию  $e^{i\omega x}$  с модулированной амплитудой  $f(x)$ .

Здесь  $\omega(b-a) \gg 1$ ,  $f(x)$  — некоторая достаточно гладкая функция,  $i$  — мнимая единица. Функции  $f(x)\cos\omega x$  и  $f(x)\sin\omega x$  являются быстро меняющимися и имеют на отрезке  $[a, b]$  порядка  $(b-a)\omega/\pi$  нулей. Если попытаться вычислить интеграл (13.55) с помощью стандартных квадратурных формул, то для обеспечения приемлемой точности на каждый "полупериод" колебаний подынтегральной функции потребуется поместить хотя бы несколько (например, порядка десяти) точек. Так как на отрезок  $[a, b]$  приходится примерно  $(b-a)\omega/\pi$  таких "полупериодов", то необходимо по меньшей мере порядка  $\omega(b-a) \gg 1$  узлов интегрирования. Следовательно, стандартный подход к вычислению интегралов вида (13.55) потребует слишком больших затрат машинного времени.

Для существенного уменьшения объема вычислений в равенстве (13.55) полезно рассматривать функцию  $\rho(x) = e^{i\omega x}$  как весовую. Тогда кусочно-полиномиальная интерполяция функции  $f(x)$  приводит к квадратурным формулам интерполяционного типа, которые принято называть *формулами Филона*.

Выведем одну из таких формул, основанную на интерполяции функции  $f(x)$  на каждом из элементарных отрезков  $[x_{k-1}, x_k]$  линейной функцией  $P_{1,k}(x) = f_{k-1} + (f_k - f_{k-1})(x - x_{k-1})/h_k$  и являющуюся аналогом составной квадратурной формулы трапеций. Положим

$$I_k = \int_{x_{k-1}}^{x_k} f(x)e^{i\omega x} dx \approx I_k^h = \int_{x_{k-1}}^{x_k} P_{1,k}(x)e^{i\omega x} dx.$$

Вычислив интеграл  $I_k^h$ , получаем формулу

$$I_k^h = \frac{h_k}{2} (A_k f_{k-1} + B_k f_k) e^{i\omega x_{k-1}/2}.$$

Здесь

$$A_k = \frac{\sin p_k}{p_k} + i \frac{p_k \cos p_k - \sin p_k}{p_k^2}, \quad B_k = \frac{\sin p_k}{p_k} - i \frac{p_k \cos p_k - \sin p_k}{p_k^2},$$

$$p_k = \frac{\omega h_k}{2}.$$

В результате приходим к составной формуле вида

$$\int_a^b f(x)e^{i\omega x} dx \approx \sum_{i=1}^n \frac{h_k}{2} (A_k f_{k-1} + B_k f_k) e^{i\omega x_{k-1}/2}.$$

**5. Аддитивное выделение особенности.** Иногда подынтегральную функцию удается представить в виде суммы  $F(x) = \varphi(x) + \psi(x)$ , где функция  $\varphi(x)$  содержит особенность, но интегрируется аналитически, а функция  $\psi(x)$  является достаточно гладкой. Тогда интеграл от функции  $F$  представляют в виде суммы двух интегралов:

$$\int_a^b F(x)dx = \int_a^b \varphi(x)dx + \int_a^b \psi(x)dx = I^{(1)} + I^{(2)}.$$

Первый из них вычисляется аналитически, а значение второго можно найти с помощью той или иной квадратурной формулы.

**Пример 13.13.** Указанный прием можно использовать для вычисления интеграла (13.45). Представим интеграл в виде

$$\int_{-1}^1 \frac{1}{\sqrt{x}} e^{-x^2} dx = \int_0^1 \frac{1-x^2}{\sqrt{x}} dx + \int_0^1 \frac{e^{-x^2} - 1 + x^2}{\sqrt{x}} dx = I^{(1)} + I^{(2)}.$$

Интеграл  $I^{(1)}$  вычисляется аналитически:  $I^{(1)} = 1.6$ . В то же время функция  $(e^{-x^2} - 1 + x^2)/\sqrt{x}$  трижды непрерывно дифференцируема на отрезке  $[0, 1]$ . Поэтому интеграл  $I^{(2)}$  можно вычислить по формуле прямоугольников. В результате приходим к формуле

$$I \approx I^h = 1.6 + h \sum_{i=1}^n \frac{1}{\sqrt{x_{i-1/2}}} (e^{-x_{i-1/2}^2} - 1 + x_{i-1/2}^2).$$

Найденные по ней приближенные значения интеграла приведены в табл. 13.5:

Т а б л и ц а 13.5

$h$	$I^h$	$I - I^h$
0.200	1.687874	$1.8 \cdot 10^{-3}$
0.100	1.689227	$4.5 \cdot 10^{-4}$
0.050	1.689565	$1.1 \cdot 10^{-4}$
0.025	1.689649	$2.8 \cdot 10^{-5}$

Конечно, отмеченные приемы представляют лишь небольшую часть тех средств, которые применяются при вычислении интегралов в нерегулярных случаях. Иногда, например, оказывается полезной замена

переменных  $x = \varphi(t)$ , приводящая интеграл к виду  $\int_a^b F(x)dx =$   
 $= \int_{\alpha}^{\beta} F(\varphi(t)) \varphi'(t)dt.$

### § 13.6. Дополнительные замечания

1. Мы не рассматриваем проблему вычисления кратного интеграла

$$I = \iiint_G f(x_1, x_2, \dots, x_m) dx_1 dx_2 \dots dx_m, \quad (13.56)$$

поскольку это потребовало бы привлечения достаточно сложного математического аппарата. Ограничимся указанием на то, что в принципе вычисление интегралов (13.56) можно проводить методами, аналогичными рассмотренным в этой главе. Соответствующие *кубатурные формулы*<sup>1</sup> для вычисления кратных интегралов имеют вид

$$I \approx \sum_{j=1}^N A_j f(x_1^{(j)}, x_2^{(j)}, \dots, x_m^{(j)}). \quad (13.57)$$

Среди формул (13.57) есть кубатурные формулы интерполяционного типа и кубатурные формулы Гаусса. Иногда для вычисления кратного интеграла оказывается целесообразным сведение его к повторному вычислению однократных интегралов. Для первоначального знакомства с методами вычисления кратных интегралов можно рекомендовать книги [9], [43].

2. Вычисление кратных интегралов уже при не очень больших значениях  $m \geq 6$  является очень сложной задачей. Применение для вычисления таких интегралов кубатурных формул типа (13.57) требует (даже при очень скромных запросах к точности) такого большого числа  $N$  вычислений значений функции  $f$ , что решение задачи даже при использовании самых современных ЭВМ становится нереальным. Привлекательной альтернативой в такой ситуации становится использование *метода Монте—Карло*. Простейшее представление об этом методе (на примере вычисления однократного интеграла) можно получить из учебника [21]. Мы все же рекомендуем обратиться и к весьма содержательному обсуждению метода Монте—Карло, проведенному в книге [9].

3. Иногда возникает необходимость по известной функции  $f(x)$ , заданной на отрезке  $[a, b]$ , восстановить ее первообразную

<sup>1</sup> Впрочем, формулы (13.57) называют также и квадратурными.

$$y(x) = \int_a^x f(\xi) d\xi, \quad a \leq x \leq b. \quad (13.58)$$

При каждом фиксированном  $x$  функцию (13.58) можно рассматривать как определенный интеграл вида (13.1) и вычислять с помощью одного из известных методов. Однако если требуется находить значения  $y(x)$  в большом числе различных точек, то такой подход становится нецелесообразным. Оказывается более выгодным разбить отрезок  $[a, b]$  на элементарные отрезки точками  $a = x_0 < x_1 < x_2 < \dots < x_n = b$ , а затем составить таблицу значений  $y_i \approx y(x_i)$ ,  $0 \leq i \leq n$ . Значения  $y_i$  можно найти, например, по формуле  $y_i = y_{i-1} + I_i^{h_i}$ ,  $1 \leq i \leq n$ . Здесь  $y_0 = 0$ , а  $I_i^{h_i}$  — приближение к интегралу  $\int_{x_{i-1}}^{x_i} f(x) dx$ , полученное с помощью одной из квадратурных формул. Значение  $y(x)$  в любой из промежуточных точек можно затем приближенно восстановить, используя интерполяцию. Так как значения  $y'(x_i) = f(x_i)$  фактически также известны, то весьма подходящим для интерполяции на каждом элементарном отрезке  $[x_{i-1}, x_i]$  является кубический многочлен Эрмита (см. § 11.5). Использование этого способа интерполяции позволяет находить значения  $y(x)$  с довольно высокой точностью по сравнительно редкой таблице значений.

4. В данной главе в основном обсуждались не вычислительные алгоритмы, а методы дискретизации, т.е. методы замены определенных интегралов соответствующими квадратурными суммами. Как бы ни был организован алгоритм, он все же предполагает вычисление квадратурной суммы. С увеличением числа слагаемых возрастает влияние вычислительной погрешности на результат суммирования. При очень больших значениях  $N$  даже для хорошо обусловленных квадратурных формул соответствующий вычислительный алгоритм может стать плохо обусловленным. Тем не менее при умеренном значении числа узлов влияние ошибок округления невелико и им часто можно пренебречь.

## Глава 14

### ЧИСЛЕННЫЕ МЕТОДЫ РЕШЕНИЯ ЗАДАЧИ КОШИ ДЛЯ ОБЫКНОВЕННЫХ ДИФФЕРЕНЦИАЛЬНЫХ УРАВНЕНИЙ

Инженеру часто приходится иметь дело с техническими системами и технологическими процессами, характеристики которых непрерывным образом меняются со временем<sup>1</sup>  $t$ . Соответствующие явления, как правило, подчиняются физическим законам, которые формулируются в виде дифференциальных уравнений. Одной из основных математических задач, которые приходится решать для таких уравнений, является *задача Коши* (или *начальная задача*). Чаще всего к ней приходят тогда, когда начальное состояние некоторой физической системы в момент времени  $t_0$  считается известным, и требуется предсказать ее поведение при  $t \geq t_0$ . Понимание того, что задача Коши описывает развитие тех или иных процессов во времени, значительно упрощает восприятие как подходов к ее решению, так и критериев оценки качества получаемых приближений.

Подавляющее большинство возникающих на практике начальных задач невозможно решить без использования вычислительной техники. Поэтому в инженерных и научно-технических расчетах численные методы решения задачи Коши играют особую роль.

Моделирование самых разнообразных процессов приводит к необходимости решать системы дифференциальных уравнений (иногда довольно высокого порядка). Тем не менее большая часть этой главы (§ 14.1 — 14.9) посвящена рассмотрению методов решения задачи Коши для одного дифференциального уравнения первого порядка. Это традиционный подход, упрощающий как изложение методов, так и понимание их сущности. Переход от случая одного уравнения к случаю систем дифференциальных уравнений не вызывает затем серъ-

---

<sup>1</sup> В роли  $t$  может выступать и другая (например, пространственная) переменная. Тем не менее в этой главе переменную  $t$  будем называть временем.

езных затруднений (по крайней мере формального характера). Некоторые особенности решения задачи Коши для систем уравнений изложены в § 14.10 и 14.11. При этом значительное внимание уделяется проблеме устойчивости численных методов и так называемым жестким задачам.

### § 14.1. Задача Коши для дифференциального уравнения первого порядка

1. **Постановка задачи.** Напомним, что *решением обыкновенного дифференциального уравнения первого порядка*

$$y'(t) = f(t, y(t)) \quad (14.1)$$

называется дифференцируемая функция  $y(t)$ , которая при подстановке в уравнение (14.1) обращает его в тождество. График решения дифференциального уравнения называют *интегральной кривой*. Процесс нахождения решений дифференциального уравнения принято называть *интегрированием* этого уравнения.

Исходя из геометрического смысла производной  $y'$  заметим, что уравнение (14.1) задает в каждой точке  $(t, y)$  плоскости переменных  $t, y$  значение  $f(t, y)$  тангенса угла  $\alpha$  наклона (к оси  $Ot$ ) касательной к графику решения, проходящего через эту точку. Величину  $k = \operatorname{tg} \alpha = f(t, y)$  далее будем называть *угловым коэффициентом* (рис. 14.1). Если теперь в каждой точке  $(t, y)$  задать с помощью некоторого вектора направление касательной, определяемое значением  $f(t, y)$ , то получится так называемое *поле*

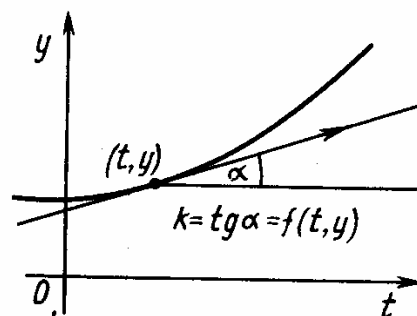


Рис. 14.1

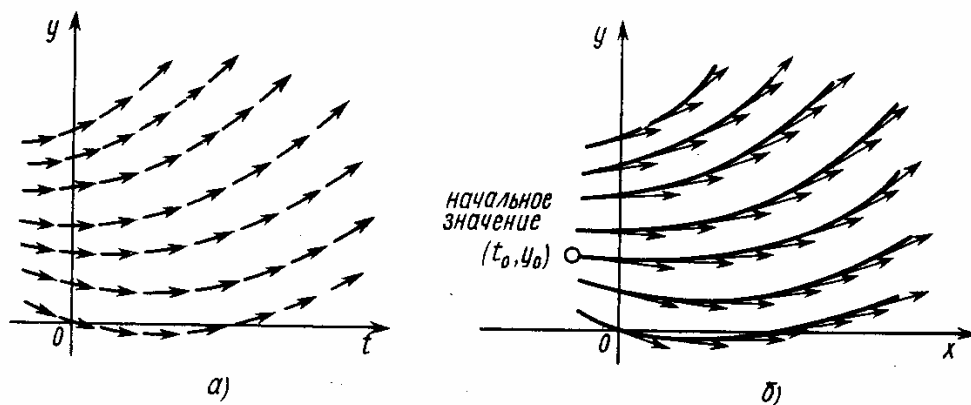


Рис. 14.2



направлений (рис. 14.2, а). Таким образом, геометрически задача интегрирования дифференциальных уравнений состоит в нахождении интегральных кривых, которые в каждой своей точке имеют заданное направление касательной (рис. 14.2, б). Для того, чтобы выделить из семейства решений дифференциального уравнения (14.1) одно конкретное решение, задают *начальное условие*

$$y(t_0) = y_0. \quad (14.2)$$

Здесь  $t_0$  — некоторое фиксированное значение аргумента  $t$ , а  $y_0$  — величина, называемая *начальным значением*. Геометрическая интерпретация использования начального условия состоит в выборе из семейства интегральных кривых той кривой, которая проходит через фиксированную точку  $(t_0, y_0)$ .

Задачу нахождения при  $t > t_0$  решения  $y(t)$  дифференциального уравнения (14.1), удовлетворяющего начальному условию (14.2), будем называть *задачей Коши*. В некоторых случаях представляет интерес поведение решения при всех  $t > t_0$ . Однако чаще ограничиваются определением решения на конечном отрезке  $[t_0, T]$ .

**2. Разрешимость задачи Коши.** Пусть  $\Pi_T$  — множество точек  $(t, y)$ , удовлетворяющих условию  $t_0 \leq t \leq T$ ,  $-\infty < y < \infty$ ; это множество будем называть *полосой*.

Приведем одну из теорем о разрешимости задачи Коши.

**Т е о р е м а 14.1.** Пусть функция  $f(t, y)$  определена и непрерывна в полосе  $\Pi_T$ . Предположим также, что она удовлетворяет условию Липшица<sup>1</sup>

$$|f(t, y_1) - f(t, y_2)| \leq L|y_1 - y_2| \quad (14.3)$$

для всех  $t_0 \leq t \leq T$  и произвольных  $y_1, y_2$ , где  $L$  — некоторая постоянная (постоянная Липшица).

Тогда для каждого начального значения  $y_0$  существует единственное решение  $y(t)$  задачи Коши (14.1), (14.2), определенное на отрезке  $[t_0, T]$ .

**З а м е ч а н и е 1.** Для дифференцируемых по  $y$  функций  $f$  условие (14.3) выполняется тогда и только тогда, когда для всех  $(t, y) \in \Pi_T$  справедливо неравенство

<sup>1</sup> Рудольф Липшиц (1832 — 1903) — немецкий математик.

$$|f'_y(t, y)| \leq L. \quad (14.4)$$

Поэтому условие (14.4) можно также называть *условием Липшица*.

**З а м е ч а н и е 2.** Теорема 14.1 остается справедливой, если в ее формулировке условие Липшица (14.3) заменить менее ограничительным *односторонним условием Липшица*

$$(f(t, y_1) - f(t, y_2))(y_1 - y_2) \leq \sigma (y_1 - y_2)^2. \quad (14.5)$$

Подчеркнем, что входящая в это условие постоянная  $\sigma$  может иметь произвольный знак.

Для дифференцируемых по  $y$  функций  $f$  условие (14.5) выполняется тогда и только тогда, когда для всех  $(t, y) \in \Pi_T$  справедливо неравенство

$$f'_y(t, y) \leq \sigma. \quad (14.6)$$

Ясно, что для функций, удовлетворяющих условию Липшица с постоянной  $L$ , одностороннее условие заведомо выполнено с постоянной  $\sigma \leq L$ .

**Пример 14.1.** Функция  $f(t) = \cos(t + y)$  удовлетворяет условию Липшица с постоянной  $L = 1$ , так как  $f'_y = -\sin(t + y)$  и  $|f'_y| \leq 1$ . Отсюда следует, что решение задачи Коши  $y' = \cos(t + y)$ ,  $y(t_0) = y_0$  существует и единственно на любом отрезке  $[t_0, T]$ .

**Пример 14.2.** Функция  $f(t, y) = t - y^3$  не удовлетворяет условию Липшица, поскольку  $f'_y = -3y^2$  и модуль этой величины не ограничен. В то же время одностороннее условие (14.6) выполняется с постоянной  $\sigma = 0$ . Следовательно, можно утверждать, что решение задачи Коши  $y' = t - y^3$ ,  $y(t_0) = y_0$  существует и единственно на любом отрезке  $[t_0, T]$ .

**Пример 14.3.** Функция  $f(t, y) = t + y^3$  не удовлетворяет одностороннему условию (14.6), так как частная производная  $f'_y = 3y^2$  не ограничена сверху. Поэтому вопрос о разрешимости задачи Коши  $y' = t + y^3$ ,  $y(t_0) = y_0$  требует дополнительного исследования.

Отметим следующий полезный результат, указывающий на зависимость степени гладкости решения задачи Коши от степени гладкости правой части дифференциального уравнения.

**Т е о р е м а 14.2.** Пусть функция  $f$  непрерывно дифференцируема  $m$  раз в полосе  $\Pi_T$ . Тогда если функция  $y$  является на отрезке  $[t_0, T]$  решением задачи Коши (14.1), (14.2), то она непрерывно дифференцируема  $m + 1$  раз на этом отрезке.

Это утверждение непосредственно вытекает из возможности дифференцирования тождества  $y'(t) \equiv f(t, y(t))$  не менее чем  $m$  раз.

В дальнейшем функции  $f$  и  $y$  будем предполагать дифференцируемыми столько раз, сколько потребуется при рассмотрении соответствующих численных методов.

**3. Устойчивость решения задачи Коши на конечном отрезке.** Этот вопрос весьма важен для понимания особенностей методов численного интегрирования дифференциальных уравнений. Рассмотрим сначала процесс распространения погрешностей, внесенных в начальные значения. Пусть  $y_0^*$  — возмущенное начальное значение,  $\varepsilon_0 = y_0 - y_0^*$  — его погрешность, а  $y^*(t)$  — решение соответствующей задачи Коши

$$(y^*)'(t) = f(t, y^*(t)), \quad (14.7)$$

$$y^*(t_0) = y_0^*.$$

Вычтем из уравнения (14.1) уравнение (14.7) и воспользуемся формулой конечных приращений Лагранжа:

$$f(t, y(t)) - f(t, y^*(t)) = \lambda(t)(y(t) - y^*(t)), \quad \lambda(t) = f'_y(t, \tilde{y}(t)),$$

где  $\tilde{y}(t)$  — некоторое промежуточное между  $y(t)$  и  $y^*(t)$  значение. В результате получим, что погрешность  $\varepsilon(t) = y(t) - y^*(t)$  удовлетворяет дифференциальному уравнению

$$\varepsilon'(t) = \lambda(t)\varepsilon(t), \quad (14.8)$$

и начальному условию

$$\varepsilon(t_0) = \varepsilon_0. \quad (14.9)$$

Решение задачи (14.8), (14.9) выражается формулой

$$\varepsilon(t) = \varepsilon_0 \exp \left\{ \int_{t_0}^t \lambda(\tau) d\tau \right\}.$$

Таким образом, величина

$$C(t) = \exp \left\{ \int_{t_0}^t \lambda(\tau) d\tau \right\} = \exp \left\{ \int_{t_0}^t f'_y(\tau, \tilde{y}(\tau)) d\tau \right\}.$$

играет в задаче Коши роль коэффициента роста ошибки.

Заметим, что знак производной  $f'_y$  оказывает существенное влияние на поведение погрешности  $\varepsilon(t)$ . Если  $f'_y > 0$ , то величина  $C(t)$ , а вместе с ней и модуль погрешности монотонно возрастают. При этом соответствующие интегральные кривые расходятся. Иллюстрацией такого поведения погрешности может служить рис. 14.3, а. Иначе ведет себя погрешность в случае  $f'_y < 0$ . Здесь  $C(t)$  и  $|\varepsilon(t)|$  с ростом  $t$  монотонно убывают, а соответствующие интегральные кривые сближаются. Ошибка, внесенная в начальное значение, имеет тенденцию к затуханию (рис. 14.3, б). В случае, когда производная  $f'_y$  незначительна, поведение погрешности может быть более сложным.

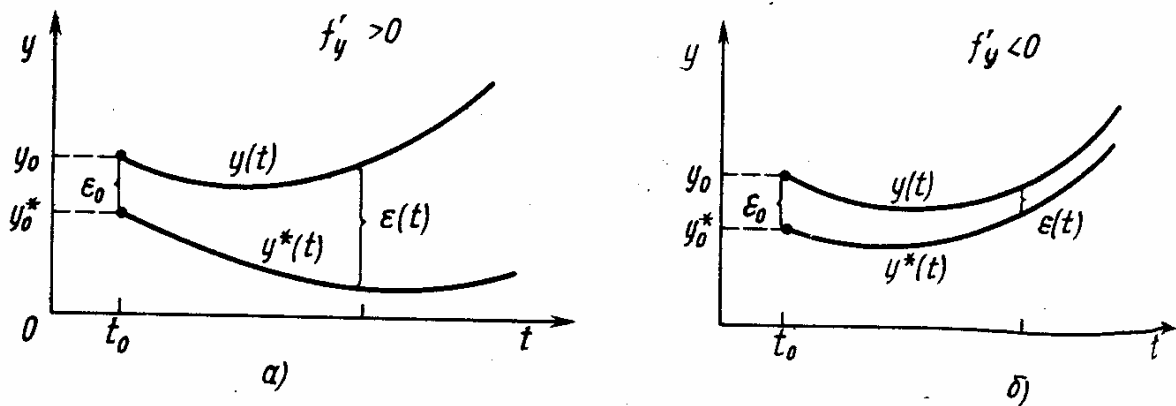


Рис. 14.3

Важно отметить, что в любом случае выполнение одностороннего условия Липшица (14.5) гарантирует, что коэффициент  $C(t)$  роста ошибки окажется ограниченным, если задача решается на конечном отрезке  $[t_0, T]$ . В самом деле, в этом случае

$$\int_{t_0}^t f'_y(\tau, \tilde{y}(\tau)) d\tau \leq \int_{t_0}^t \sigma d\tau = \sigma(t - t_0)$$

и поэтому  $C(t) \leq K(T)$  для всех  $t_0 \leq t \leq T$ , где

$$K(T) = \begin{cases} e^{\sigma(T-t_0)} & \text{при } \sigma > 0, \\ 1 & \text{при } \sigma \leq 0. \end{cases} \quad (14.10)$$

Таким образом, при выполнении условия  $f'_y \leq \sigma$  справедлива оценка

$$\max_{t_0 \leq t \leq T} |y(t) - y^*(t)| \leq K(T) |y_0 - y_0^*|, \quad (14.11)$$

выражающая устойчивость на конечном отрезке  $[t_0, T]$  решения задачи Коши по начальным значениям.

**4. Модельное уравнение.** Наиболее простым образом ведет себя погрешность в случае, когда решается линейное уравнение

$$y'(t) = \lambda y(t) + f(t)$$

с постоянным коэффициентом  $\lambda$ . В этом случае погрешность  $\varepsilon$  удовлетворяет уравнению  $\varepsilon'(t) = \lambda \varepsilon(t)$  и выражается формулой

$$\varepsilon(t) = \varepsilon_0 e^{\lambda(t-t_0)}. \quad (14.12)$$

Поскольку функция  $f(t)$  не влияет на характер распространения погрешности, при изучении устойчивости по начальным значениям естественно ограничиться случаем  $f(t) \equiv 0$  и рассматривать уравнение

$$y'(t) = \lambda y(t). \quad (14.13)$$

Уравнение (14.13) часто называют *модельным уравнением*. Оно играет важную роль при исследовании свойств численных методов решения задачи Коши.

Как следует из формулы (14.12), модуль погрешности решения уравнения (14.13) изменяется в  $e$  раз за интервал времени  $\tau = 1/|\lambda|$ . Поэтому величину  $\tau = 1/|\lambda|$  иногда называют *временной постоянной* или *постоянной времени* модельного уравнения (14.13). Если же параметр  $\lambda$  является комплексным числом, то временной постоянной называют величину  $\tau = \frac{1}{|\operatorname{Re} \lambda|}$ .

В случае, когда рассматривается распространение малого возмущения, внесенного в решение  $y(t)$  уравнения  $y' = f(t, y)$  в малой окрестности точки  $\tilde{t}$ , значение коэффициента  $\lambda(t)$  в уравнении (14.8) оказывается близко к постоянной  $\tilde{\lambda} = f'_y(\tilde{t}, y(\tilde{t}))$ . Поэтому при  $t \approx \tilde{t}$  справедливо приближенное равенство  $\varepsilon'(t) \approx \tilde{\lambda} \varepsilon(t)$ . Это означает, что поведение погрешности для уравнения  $y' = \tilde{\lambda} y$  моделирует локальное распространение погрешности для общего уравнения (14.1). Роль временной постоянной играет здесь величина  $\tau(\tilde{t}) = \frac{1}{|\tilde{\lambda}|} =$

$= \frac{1}{|f'_y(\tilde{t}, y(\tilde{t}))|}$ . Так как ее значение меняется с изменением точки  $\tilde{t}$ , то ее называют *локальной временной постоянной*. Если же функция  $f$

может принимать комплексные значения, то формула для  $\tau$  имеет вид

$$\tau(\tilde{t}) = \frac{1}{|\operatorname{Ref}'_y(\tilde{t}, y(\tilde{t}))|}.$$

**5. Устойчивость по правой части.** Будет ли решение задачи Коши устойчивым не только по отношению к погрешности  $\varepsilon_0$  задания начального значения, но и к погрешностям  $\psi(t)$  задания правой части уравнения? Положительный ответ на этот вопрос дает следующая теорема.

**Теорема 14.3.** Пусть выполнены условия теоремы 14.1. Далее, пусть  $y(t)$  — решение задачи (14.1), (14.2), а  $y^*(t)$  — решение задачи

$$(y^*)'(t) = f(t, y^*(t)) + \psi(t), \quad (14.14)$$

$$y^*(t_0) = y_0^*. \quad (14.15)$$

Тогда справедлива оценка

$$\max_{t_0 \leq t \leq T} |y(t) - y^*(t)| \leq K(T)(|y_0 - y_0^*| + \int_{t_0}^T |\psi(t)| dt), \quad (14.16)$$

выражающая устойчивость на конечном отрезке  $[t_0, T]$  решения задачи Коши по начальным значениям и правой части. Здесь  $K(T) = e^{L(T-t_0)}$ .

**З а м е ч а н и е.** Величина  $K(T)$  играет в задаче Коши роль оценки числа обусловленности<sup>1</sup>. Если в теореме 14.1 условие Липшица (14.3) заменить односторонним условием (14.5), то оценка (14.16) будет выполнена с постоянной  $K(T)$ , определенной формулой (14.10).

**6. Устойчивость решения на неограниченном промежутке.** При решении самых разнообразных прикладных задач особый интерес представляет изучение описываемых дифференциальными уравнениями процессов на больших временных отрезках. В такой ситуации недостаточно наличия у задачи Коши свойства устойчивости на конечном отрезке. Если входящая в неравенство (14.16) величина  $K(T)$  может неограниченно расти с ростом  $T$ , то это означает, что допускается неограниченный при  $T \rightarrow \infty$  рост погрешностей. Как следствие, при достаточно больших  $T$  такая задача является плохо обусловленной и найти ее решение на отрезке  $[t_0, T]$  с приемлемой точностью оказывается невозможно.

<sup>1</sup> Напомним, что общее понятие о числе обусловленности вычислительной задачи содержится в гл. 3.

**Пример 14.4.** Рассмотрим задачу Коши  $y'(t) = y(t) - \sin t + \cos t$ ,  $y(0) = 0$ . Ее решением, как нетрудно проверить, является функция  $y(t) = \sin t$ .

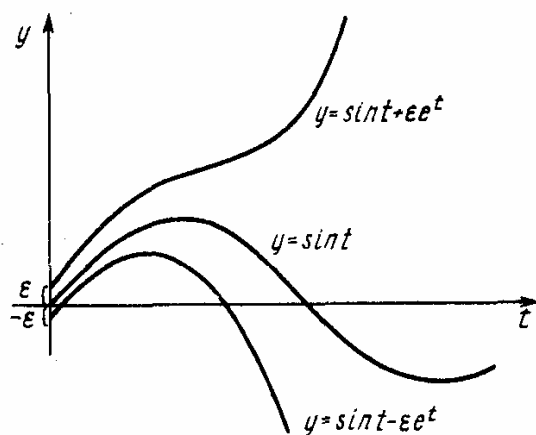


Рис. 14.4

Внесем в начальное значение погрешность, заменив условие  $y(0) = 0$  условием  $y(0) = \varepsilon$ . Решением соответствующей задачи служит уже функция  $y(t) = \sin t + \varepsilon e^t$ . Погрешность  $\varepsilon e^t$  с ростом  $t$  быстро увеличивается и, как видно из рис. 14.4, уже при не очень больших  $t$  ее значение становится неприемлемо большим.

Для того чтобы обусловленность задачи Коши не ухудшалась с ростом  $T$ , в силу замечания 1 к теореме 14.3 достаточно потребовать, чтобы правая часть уравнения удовлетворяла неравенству  $f'_y(t, y) \leq 0$  для всех  $t \geq t_0$  и произвольных  $y$ . Более того, можно доказать, что при выполнении условия  $f'_y(t, y) \leq \sigma < 0$  справедлива следующая оценка:

$$|y(t) - y^*(t)| \leq e^{\sigma(t-t_0)} |y_0 - y_0^*| + \frac{1}{|\sigma|} \max_{t_0 \leq t' \leq t} |\psi(t')|. \quad (14.17)$$

Предположим, что на каждом отрезке  $[t_0, T]$  ( $t_0 < T$  — произвольное) неравенство (14.6) выполнено с некоторой постоянной  $\sigma = \sigma(T)$ . Тогда решение  $y(t)$  определено для всех  $t_0 \leq t < \infty$ . Пусть  $y^*(t)$  — решение уравнения (14.7), отвечающее произвольному начальному значению  $y_0^*$ . Назовем решение задачи Коши (14.1), (14.2) *устойчивым*

по Ляпунову<sup>1</sup>, если справедлива оценка  $\max_{t_0 \leq t \leq T} |y(t) - y^*(t)| \leq$

$K|y_0 - y_0^*|$ , где постоянная  $K$  не зависит от  $T$ . Если дополнительно известно, что  $y^*(t) - y(t) \rightarrow 0$  при  $t \rightarrow \infty$ , то решение  $y(t)$  называется *асимптотически устойчивым*.

**З а м е ч а н и е 1.** Решения модельного уравнения (14.13) с вещественным параметром  $\lambda$  устойчивы по Ляпунову тогда и только

<sup>1</sup> Александр Михайлович Ляпунов (1857—1918) — русский математик и механик. Приведенное здесь определение устойчивости по Ляпунову является более грубым, чем классическое определение [93].

тогда, когда  $\lambda \leq 0$ , и асимптотически устойчивы тогда и только тогда, когда  $\lambda < 0$ . Этот вывод легко следует из формулы (14.12).

Если же параметр  $\lambda$  — комплексное число, то из той же формулы следует, что  $|\varepsilon(t)| = |\varepsilon_0| e^{\operatorname{Re} \lambda (T-t_0)}$ . Поэтому решения модельного уравнения устойчивы по Ляпунову тогда и только тогда, когда  $\operatorname{Re} \lambda \leq 0$ , и асимптотически устойчивы тогда и только тогда, когда  $\operatorname{Re} \lambda < 0$ .

**З а м е ч а н и е 2.** Для решения задачи Коши (14.1), (14.2) (как вытекает из неравенства (14.11) и формулы (14.10)) грубым достаточным условием устойчивости по Ляпунову служит выполнение неравенства  $f'_y \not\leq 0$ . Следствием выполнения условия  $f'_y \leq \sigma$  с постоянной  $\sigma < 0$  является асимптотическая устойчивость решения.

## § 14.2. Численные методы решения задачи Коши.

### Основные понятия и определения

**1. Сетки и сеточные функции.** Первый этап на пути построения численного метода решения задачи Коши состоит в замене отрезка

$[t_0, T]$  — области непрерывного изменения аргумента  $t$  — множеством  $\bar{\omega}^h$ , которое состоит из конечного числа точек  $t_0 < t_1 < \dots < t_N = T$  и называется *сеткой*. Сами точки  $t_i$  называются *узлами сетки*, а величина  $h_n = t_n - t_{n-1}$  — *шагом сетки* (рис. 14.5). Для того что-

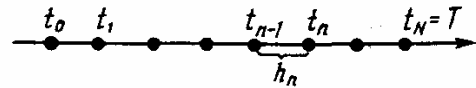


Рис. 14.5

бы упростить изложение, будем рассматривать, как правило, *равномерные сетки*, т.е. такие сетки, для которых шаг  $h_n$  постоянен. В этом случае  $h_n = h = \frac{T - t_0}{N}$  и  $t_n = t_0 + nh$ ,  $n = 1, 2, \dots, N$ .

Наряду с функциями непрерывного аргумента будем рассматривать и *сеточные функции*, т.е. такие функции, которые определены лишь в узлах сетки  $\bar{\omega}^h$ . Для того чтобы отличать сеточные функции от функций непрерывного аргумента, будем помечать их индексом  $h$ . Так, например  $u^h$  — сеточная функция. Для краткости записи значения  $u^h(t_n)$  сеточной функции  $u^h$  в узлах  $t_n$  сетки  $\bar{\omega}^h$  будем обозначать через  $u_n$ .

**2. Дискретная задача Коши.** Следующий этап в построении численного метода состоит в замене задачи Коши ее дискретным аналогом — системой уравнений, решая которую можно последовательно найти значения  $y_1, y_2, \dots, y_N$  сеточной функции  $y^h$ , играющие роль приближений к значениям решения задачи Коши в узлах сетки  $\omega^h$ .



В основе построения конкретного численного метода лежит тот или иной способ замены дифференциального уравнения  $y' = f(t, y)$  его дискретным аналогом — уравнением вида

$$\frac{1}{h} \sum_{j=0}^k \alpha_j y_{n+1-j} = \Phi(t_n, y_{n+1-k}, \dots, y_n, y_{n+1}, h), \quad (14.18)$$

в которое входят значения сеточной функции  $y^h$  в  $k + 1$  последовательных точках  $t_{n+1-k}, \dots, t_n, t_{n+1}$ . Предполагается, что  $\alpha_0 \neq 0$ .

Во всех рассматриваемых в этой главе методах сумму

$$\frac{1}{h} (\alpha_0 y_{n+1} + \alpha_1 y_n + \dots + \alpha_k y_{n+1-k}), \quad (14.19)$$

стоящую в левой части уравнения (14.18), можно рассматривать как разностную аппроксимацию производной  $y'$  в соответствии с одной из формул численного дифференцирования (см. гл. 12). Правую часть  $\Phi$  уравнения (14.18) можно рассматривать как специальным образом построенную аппроксимацию функции  $f$ .

Значение  $y_{n+1}$  приближенного решения в очередной точке находится из уравнения (14.18). При этом используются найденные ранее значения сеточной функции  $y^h$  в  $k$  предыдущих точках  $t_{n+1-k}, \dots, t_n$ . Поэтому такие методы получили название *k-шаговых*. Как нетрудно видеть, для того чтобы найти значения сеточной функции  $y^h$  во всех узлах сетки  $\bar{\omega}^h$ , используя  $k$ -шаговый метод, необходимо задать  $k$  начальных значений:

$$y^h(t_0) = y_0, y^h(t_1) = y_1, \dots, y^h(t_{k-1}) = y_{k-1}. \quad (14.20)$$

Задачу вычисления сеточной функции  $y^h$ , удовлетворяющей уравнению (14.18) для всех  $n \geq k - 1$  и принимающей заданные начальные значения (14.20), будем называть *дискретной задачей Коши*.

**З а м е ч а н и е.** Принято считать, что уравнением (14.18) задается численный метод решения задачи Коши. Далее мы будем отождествлять свойства численного метода, дискретного уравнения (14.18) и соответствующей дискретной задачи Коши.

При  $k = 1$  уравнение (14.18) упрощается и принимает вид

$$\frac{y_{n+1} - y_n}{h} = \Phi(t_n, y_n, y_{n+1}, h). \quad (14.21)$$

Соответствующий метод принято называть *одношаговым*. Вычисление значения  $y_{n+1}$  осуществляется здесь с использованием только одного предыдущего значения  $y_n$ . Поэтому одношаговые методы часто называют *самостартующими*.

**Пример 14.5.** Простейший дискретный аналог дифференциального уравнения (14.1) представляет собой уравнение

$$\frac{y_{n+1} - y_n}{h} = f(t_n, y_n), \quad (14.22)$$

приводящее к известному *методу Эйлера*<sup>1</sup>.

**Пример 14.6.** Метод Эйлера является примером одношагового метода. Вычисление очередного значения  $y_{n+1}$  осуществляется здесь по формуле

$$y_{n+1} = y_n + hf(t_n, y_n). \quad (14.23)$$

При  $k > 1$  численный метод называют *многошаговым*. Примеры таких методов можно найти в § 14.7 и 14.10.

**З а м е ч а н и е.** Использование многошагового метода предполагает преодоление одной специфической трудности, не возникающей при применении одношаговых методов. Как уже отмечалось выше,  $k$ -шаговый метод требует задания  $k$  начальных значений (14.20), в то время как в постановке задачи Коши содержится только одно начальное значение  $y_0$ . Поэтому при  $k > 1$  метод не является самостартующим и для вычисления дополнительных значений  $y_1, y_2, \dots, y_{k-1}$  необходимы специальные подходы.

**3. Явные и неявные методы.** Реализация численного метода на ЭВМ предполагает построение алгоритма, позволяющего вычислить решение поставленной дискретной задачи Коши. В случае, когда входящая в уравнение (14.18) функция  $\Phi$  не зависит от  $y_{n+1}$ , вычисление значения  $y_{n+1}$  не вызывает затруднений и осуществляется по явной формуле

$$y_{n+1} = \alpha_0^{-1} \left[ - \sum_{j=1}^k \alpha_j y_{n+1-j} + h \Phi(t, y_{n+1-k}, \dots, y_n, h) \right].$$

Поэтому соответствующие методы называют *явными*. В противоположность им, методы, в которых функция  $\Phi$  зависит от  $y_{n+1}$ , называют *неявными*. При реализации неявного метода при каждом  $n$  (или, как говорят, на каждом шаге) возникает необходимость решения относительно  $y_{n+1}$  нелинейного уравнения (14.18).

**Пример 14.7.** Метод Эйлера, для которого вычисления  $y_{n+1}$  производятся по явной формуле (14.23), представляет собой явный метод.

---

<sup>1</sup> Леонард Эйлер (1707 — 1783) — математик, физик, механик, астроном. Родился в Швейцарии, с 1726 по 1741 г. и с 1776 по 1783 г. работал в России.

**Пример 14.8.** Простейшим примером неявного метода является *неявный метод Эйлера*, соответствующий аппроксимации дифференциального уравнения (14.1) дискретным уравнением

$$\frac{y_{n+1} - y_n}{h} = f(t_{n+1}, y_{n+1}). \quad (14.24)$$

Другим примером неявного метода может служить *правило трапеций*

$$\frac{y_{n+1} - y_n}{h} = \frac{1}{2} (f(t_n, y_n) + f(t_{n+1}, y_{n+1})). \quad (14.25)$$

Как в том, так и в другом методе значение  $y_{n+1}$  определяется уравнением неявно, и для его вычисления приходится использовать один из итерационных методов решения нелинейных уравнений.

**4. Устойчивость.** Если решение дискретной задачи Коши не обладает устойчивостью по отношению к малым возмущениям начальных значений и правой части уравнения, то соответствующий численный метод нельзя использовать в практических вычислениях. Приведем определение устойчивости, достаточное для понимания основного содержания этого и следующих четырех параграфов. Более подробно обсуждение этой проблемы будет проведено в § 14.8.

Внесем в правую часть уравнения (14.18) и в начальные условия (14.20) произвольные малые возмущения  $\psi_n$  и  $\varepsilon_0, \varepsilon_1, \varepsilon_2, \dots, \varepsilon_{k-1}$  соответственно. Положим  $y_0^* = y_0 - \varepsilon_0, y_1^* = y_1 - \varepsilon_1, \dots, y_{k-1}^* = y_{k-1} - \varepsilon_{k-1}$ . Пусть  $y^{*h}$  — решение соответствующей возмущенной задачи

$$\frac{1}{h} \sum_{j=0}^k y_{n+1-j}^* = \Phi(t_n, y_{n+1-k}^*, \dots, y_n^*, y_{n+1}^*, h) + \psi_n, \quad (14.26)$$

$$y^{*h}(t_0) = y_0^*, y^{*h}(t_1) = y_1^*, \dots, y^{*h}(t_{k-1}) = y_{k-1}^*. \quad (14.27)$$

Будем называть дискретную задачу Коши (14.18), (14.20) и соответствующий численный метод *устойчивыми на конечном отрезке* (или просто *устойчивыми*), если при всех  $h \leq h_0$  (где  $h_0$  достаточно мало) справедливо неравенство

$$\max_{0 \leq n \leq N} |y_n - y_n^*| \leq \bar{K}(T) \left[ \max_{0 \leq n \leq k-1} |\varepsilon_n| + \sum_{n=k-1}^{N-1} |\psi_n| \cdot h \right], \quad (14.28)$$

где величина  $\bar{K}$  не зависит от  $h, \varepsilon_n$  ( $0 \leq n \leq k-1$ ) и  $\psi_n$  ( $k-1 \leq n \leq N-1$ ).

**З а м е ч а н и е.** Неравенство (14.28) является дискретным аналогом неравенства (14.16), выражающего устойчивость задачи Коши. Для одношаговых методов (т.е. при  $k = 1$ ) неравенство (14.28) принимает вид

$$\max_{0 \leq n \leq N} |y_n - y_n^*| \leq \bar{K}(T)(|\varepsilon_0| + \sum_{n=0}^{N-1} |\psi_n| \cdot h),$$

и аналогия с (14.16) становится еще более очевидной. Действительно, сумму  $\sum_{n=0}^{N-1} |\psi_n| \cdot h$  можно рассматривать как дискретный аналог интеграла  $\int_{t_0}^T |\psi(t)| dt$ , построенный по формуле левых прямоугольников (см. § 13.1).

**5. Аппроксимация.** Пусть  $y(t)$  — произвольная гладкая функция. Зафиксируем значение  $t = t_n$  и устремим  $h$  к нулю (а  $n$  соответственно — к бесконечности). Будем предполагать, что замена в формуле (14.19) значений  $y_{n+1-j}$  сеточной функции  $y^h$  соответствующими значениями  $y(t - (j-1)h)$  функции  $y$  дает величину

$$\frac{1}{h} (\alpha_0 y(t+h) + \alpha_1 y(t) + \dots + \alpha_k y(t - (k-1)h)), \quad (14.29)$$

стремящуюся к  $y'(t)$  при  $h \rightarrow 0$ .

Аналогично предположим, что

$$\Phi(t, y(t - (k-1)h), \dots, y(t), y(t+h), h) \rightarrow f(t, y(t)) \text{ при } h \rightarrow 0.$$

**З а м е ч а н и е.** Из сделанных предположений следует, что коэффициенты  $\alpha_0, \alpha_1, \dots, \alpha_k$  должны удовлетворять условию

$$\alpha_0 + \alpha_1 + \dots + \alpha_k = 0. \quad (14.30)$$

В самом деле, для  $y(t) \equiv 1$  величина (14.29) превращается в  $\frac{\bar{\alpha}}{h}$ ,

где  $\bar{\alpha} = \sum_{j=0}^k \alpha_j$ . По условию,  $\frac{\bar{\alpha}}{h} \rightarrow y'(t) = 0$  при  $h \rightarrow 0$ . Но это возможно

лишь при  $\bar{\alpha} = 0$ , что эквивалентно равенству (14.30).

Пусть  $y(t)$  — решение задачи Коши (14.1), (14.2). Назовем сеточную функцию  $\psi^h$ , определяемую формулой

$$\psi_n = \frac{1}{h} \sum_{j=0}^k \alpha_j y(t_{n+1-j}) - \Phi(t_n, y(t_{n+1-k}), \dots, y(t_{n+1}), h),$$

погрешностью аппроксимации дискретного уравнения (14.18) на решении  $y$ . Эта же формула, записанная в виде

$$\frac{1}{h} \sum_{j=0}^k \alpha_j y(t_{n+1-j}) = \Phi(t_n, y(t_{n+1-k}), \dots, y(t_{n+1}), h) + \psi_n, \quad (14.31)$$

позволяет заметить, что функция  $y(t)$  удовлетворяет уравнению (14.18) с точностью до погрешности аппроксимации  $\psi_n$ .

Сеточную функцию  $\psi^h$  используют для предварительной оценки того, насколько точно аппроксимируется дифференциальное уравнение его дискретным аналогом. Говорят, что *дискретное уравнение (14.18) аппроксимирует дифференциальное уравнение (14.1), если*

$\max_{k-1 \leq n < N} |\psi_n| \rightarrow 0$  при  $h \rightarrow 0$ , и *аппроксимирует его с  $p$ -м порядком,*

если справедлива оценка  $\max_{k-1 \leq n < N} |\psi_n| \leq Ch^p$ ,  $p > 0$ .

Часто для оценки качества одношаговых методов (14.21) используют не погрешность аппроксимации, а другую величину — локальную погрешность. Пусть  $y_{n+1}$  — значение, найденное из уравнения

$$\frac{y_{n+1} - y(t_n)}{h} = \Phi(t_n, y(t_n), y_{n+1}, h), \quad (14.32)$$

т.е. из уравнения (14.21), в которое вместо  $y_n$  подставлено точное значение решения дифференциального уравнения в точке  $t = t_n$ . Тогда разность  $l_n = y(t_{n+1}) - y_{n+1}$  называется *локальной погрешностью метода* (или его *погрешностью на шаге*). Другими словами,  $l_n$  — это погрешность, которую допускает за один шаг метод, стартовавший с точного решения.

В случае, когда  $\Phi$  не зависит от  $y_{n+1}$  (т.е. метод (14.21) является явным), локальная погрешность и погрешность аппроксимации оказываются связаны простым равенством  $l_n = \psi_n h$ , что непосредственно вытекает из данных определений.

**Пример 14.9.** Покажем, что метод Эйлера имеет первый порядок аппроксимации.

Известно, что

$$\frac{y(t_n + h) - y(t_n)}{h} = y'(t_n) + \frac{h}{2} y''(\xi_n),$$

где  $t_n < \xi_n < t_{n+1}$  (см. § 12.1). Учитывая равенство  $y'(t_n) = f(t_n, y(t_n))$ , для погрешности аппроксимации получаем следующее выражение:

$$\psi_n = \frac{y(t_n + h) - y(t_n) - hf(t_n, y(t_n))}{h} = \frac{h}{2} y''(\xi_n). \quad (14.33)$$

Поэтому

$$\max_{0 \leq n < N} |\psi_n| \leq \frac{M_2}{2} h, \quad M_2 = \max_{[t_0, T]} |y''(t)|, \quad (14.34)$$

т.е. метод действительно имеет первый порядок аппроксимации.

**Пример 14.10.** Для погрешности аппроксимации неявного метода Эйлера (14.24) также справедлива оценка (14.34) и поэтому он также имеет первый порядок аппроксимации. Простое доказательство этого факта рекомендуем провести в качестве упражнения.

**Пример 14.11.** Найдем выражение для локальной погрешности метода Эйлера.

По определению,  $l_n = y(t_{n+1}) - y_{n+1}$ , где  $y_{n+1} = y(t_n) + hf(t_n, y(t_n))$ . Но в силу равенства (14.33)  $y(t_{n+1}) = y(t_n) + hf(t_n, y(t_n)) + h\psi_n = y_{n+1} + h\psi_n$ . Поэтому  $l_n = h\psi_n = \frac{h^2}{2} y''(\xi_n)$ . Таким образом, локальная погрешность метода Эйлера имеет второй порядок малости относительно шага  $h$ .

**6. Сходимость.** Пусть  $y(t)$  — решение задачи Коши. Назовем *глобальной погрешностью* (или просто *погрешностью*) численного метода сеточную функцию  $\varepsilon^h$  со значениями  $\varepsilon_n = y(t_n) - y_n$  в узлах  $t_n$ . В качестве меры абсолютной погрешности метода примем величину  $E(h) = \max_{0 \leq n \leq N} |y(t_n) - y_n|$ .

Численный метод решения задачи Коши называют *сходящимся*, если для него  $E(h) \rightarrow 0$  при  $h \rightarrow 0$ . Принято говорить, что *метод сходится с  $p$ -м порядком точности* (или *имеет  $p$ -й порядок точности*), если для погрешности справедлива оценка  $E(h) \leq Ch^p$ ,  $p > 0$ .

Покажем теперь, что для устойчивого численного метода из наличия аппроксимации с порядком  $p$  следует сходимость с тем же порядком. Будем предполагать, что начальные значения  $y_1, y_2, \dots, y_{k-1}$  заданы с  $p$ -м порядком точности<sup>1</sup>, т.е. верна оценка  $\max_{1 \leq n \leq k-1} |y(t_n) - y_n| \leq C_0 h^p$ .

$1 \leq n \leq k-1$

Справедлива следующая основная теорема.

<sup>1</sup> Для одношаговых методов это предположение излишне.

**Теорема 14.4.** Пусть численный метод устойчив на конечном отрезке и имеет порядок аппроксимации, равный  $p$ . Тогда если начальные значения  $y_1, \dots, y_{k-1}$  заданы с  $p$ -м порядком точности, то и метод сходится с  $p$ -м порядком точности.

□ Пусть  $\psi_n$  — погрешность аппроксимации. Положим  $y_n^* = y(t_n)$ . Равенство (14.31) позволяет утверждать, что сеточная функция  $y^{*h}$  является решением дискретной задачи Коши (14.26), (14.27). Устойчивость метода означает выполнение неравенства (14.28), которое в силу равенств  $y_n^* = y(t_n)$  и  $y(t_0) = y_0$  можно переписать так:

$$\max_{0 \leq n \leq N} |y(t_n) - y_n| \leq \bar{K}(T) \left[ \max_{1 \leq n \leq k-1} |y(t_n) - y_n| + \sum_{n=k-1}^{N-1} |\psi_n| \cdot h \right]. \quad (14.35)$$

Учитывая, что

$$\sum_{n=k-1}^{N-1} |\psi_n| \cdot h \leq (T - t_0) \max_{0 \leq n < N} |\psi_n| \leq (T - t_0) Ch^p,$$

правую часть неравенства (14.35) можно оценить величиной  $\bar{K}(T)(C_0 + (T - t_0)C)h^p = \bar{C}h^p$ . Итак,  $\max_{0 \leq n \leq N} |y(t_n) - y_n| \leq \bar{C}h^p$ . ■

**6. Связь с задачей вычисления интеграла.** Существует тесная связь между проблемой решения задачи Коши и задачей вычисления интеграла с переменным верхним пределом

$$y(t) = \int_{t_0}^t f(\tau) d\tau, \quad t_0 \leq t \leq T. \quad (14.36)$$

Действительно, вычисление интеграла (14.36) эквивалентно решению задачи Коши

$$y'(t) = f(t), \quad y(t_0) = 0; \quad (14.37)$$

являющейся частным случаем более общей задачи (14.1), (14.2).

Таким образом, всякий численный метод решения задачи Коши порождает соответствующий метод численного интегрирования. Например, метод Эйлера  $y_{n+1} = y_n + hf(t_n)$  приводит к формуле левых прямоугольников:

$$y(t_n) \approx y_n = h \sum_{i=0}^{n-1} f(t_i). \quad (14.38)$$

Неявный метод Эйлера  $y_{n+1} = y_n + hf(t_{n+1})$  дает формулу правых прямоугольников:

$$y(t_n) \approx y_n = h \sum_{i=1}^n f(t_i),$$

а правило трапеций (14.25) приводит к известной формуле трапеций

$$y(t_n) \approx \frac{h}{2} \sum_{i=1}^n (f(t_{i-1}) + f(t_i)).$$

На примере формулы (14.38) легко увидеть различие между локальной и глобальной погрешностями. Локальная погрешность — это погрешность, допускаемая на одном элементарном отрезке, т.е.

$$l_n = \int_{t_n}^{t_{n+1}} f(t) dt - hf(t_n),$$

а глобальная погрешность — это результирующая погрешность, т.е.

$$\varepsilon_n = \int_{t_0}^{t_n} f(t) dt - h \sum_{i=0}^{n-1} f(t_i).$$

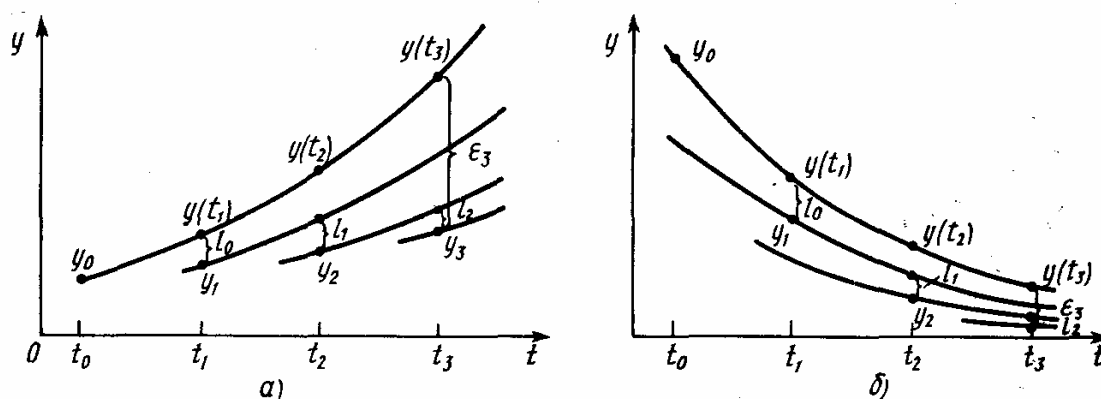


Рис. 14.6

В данном случае в силу линейности задачи (14.36) глобальная погрешность есть просто сумма локальных погрешностей:  $\varepsilon_n = \sum_{i=0}^{n-1} l_i$ .

Для нелинейного уравнения  $y' = f(t, y)$  это уже не так. В зависимости от характера поведения интегральных кривых глобальная ошибка



может оказаться больше (рис. 14.6, а) или меньше (рис. 14.6, б) суммы соответствующих локальных погрешностей.

### § 14.3. Использование формулы Тейлора

Один из наиболее простых для понимания подходов к решению задачи Коши основан на использовании формулы Тейлора

$$y(t+h) = y(t) + y'(t)h + \frac{y''(t)}{2!}h^2 + \dots + \frac{y^{(p)}(t)}{p!}h^p + R_{p+1}(t, h). \quad (14.39)$$

Здесь  $R_{p+1}(t, h) = \frac{y^{(p+1)}(\xi)}{(p+1)!}h^{p+1}$  — остаточный член формулы Тейлора,  $\xi$  — некоторая точка, принадлежащая отрезку  $[t, t+h]$ .

Отбрасывая остаточный член, получаем приближенное равенство

$$y(t+h) \approx y(t) + y'(t)h + \frac{y''(t)}{2!}h^2 + \dots + \frac{y^{(p)}(t)}{p!}h^p. \quad (14.40)$$

Если значение решения  $y$  в точке  $t$  известно, то в силу равенства

$$y'(t) = f(t, y(t)) \quad (14.41)$$

значение производной  $y'(t)$  также можно считать известным. Для того чтобы вычислить производные  $y''$ ,  $y'''$ , ... более высокого порядка, входящие в формулу (14.40), продифференцируем равенство (14.41) по  $t$ , используя правило дифференцирования сложной функции. Тогда получим

$$y'' = f'_t + f'_y y' = f'_t + f'_y f, \quad (14.42)$$

$$\begin{aligned} y''' &= f''_{tt} + f''_{ty} y' + (f''_{yt} + f''_{yy} y')f + f'_y(f'_t + f'_y y') = \\ &= f''_{tt} + 2f''_{ty} f + f'_y f'_t + (f'_y)^2 f + f''_{yy} f^2 \end{aligned} \quad (14.43)$$

и т.д. Как нетрудно заметить, выражения для производных  $y^{(k)}$  усложняются по мере роста порядка  $k$ .

Использование приближенной формулы (14.40) приводит к следующему явному одношаговому методу:

$$y_{n+1} = y_n + y'_n h + \frac{y''_n}{2!}h^2 + \dots + \frac{y^{(p)}_n}{p!}h^p. \quad (14.44)$$

Здесь  $y'_n = f(t_n, y_n)$ ; значения  $y''_n$  и  $y'''_n$  получаются в результате под-

становки в формулы (14.42) и (14.43) значений  $t = t_n$  и  $y = y_n$ ; аналогично вычисляются значения  $y_n^{(k)}$  при  $k > 3$ .

Локальная погрешность этого метода  $l_n$  совпадает с величиной  $R_{p+1}(t_n, h)$  остаточного члена формулы Тейлора, пропорциональной  $h^{p+1}$ . Пользуясь этим, можно доказать, что метод (14.44) сходится и имеет порядок точности, равный  $p$ .

Несмотря на то, что рассматриваемый метод теоретически дает возможность найти решение с любым порядком точности, на практике он применяется довольно редко. Дело в том, что использование формулы (14.44) приводит к необходимости вычисления большого числа частных производных  $\frac{\partial^{l+s} f}{\partial t^l \partial y^s}$ , что чаще всего является весьма трудоемкой и нередко аналитически невыполнимой операцией.

Более существенный аргумент против использования метода (14.44) состоит в том, что к настоящему времени разработаны эффективные численные методы решения задачи Коши (например, методы Рунге—Кутты и Адамса), предполагающие необходимость вычисления значений только функции  $f$  и не использующие ее частные производные. Именно этим методам, реализованным в виде стандартных программ и пакетов прикладных программ, мы и уделим основное внимание в дальнейшем.

Тем не менее для решения некоторых специальных классов задач приведенный выше метод может быть полезен. В частности, он используется при решении некоторых задач небесной механики, в которых вычисление производных  $y^{(k)}$  не требует существенных дополнительных затрат в силу специальной структуры правых частей.

**Пример 14.12.** Найдем численное решение задачи Коши

$$y' = 2ty, \quad y(0) = 1 \quad (14.45)$$

на отрезке  $[0, 1]$ , используя метод (14.44) при  $p = 2$ , обладающий вторым порядком точности. Как нетрудно проверить, точным решением этой задачи является функция  $y(t) = e^{t^2}$ .

Дифференцируя уравнение по  $t$ , получим следующее выражение для второй производной:  $y'' = 2y + 2ty' = 2(1 + 2t^2)y$ . Поэтому расчетная формула (14.44) в данном случае примет вид

$$y_{n+1} = y_n + h2t_n y_n + \frac{h^2}{2} 2(1 + 2t_n^2)y_n = (1 + 2t_n h + (1 + 2t_n^2)h^2) y_n.$$

Найденное по этой формуле для  $h = 0.1$  приближенное решение приведено в табл. 14.1. Для сравнения в ней же приведены значения точного решения.

Т а б л и ц а 14.1

$t$	Метод (14.44); $h = 0.1$	Точное решение	$t$	Метод (14.44); $h = 0.1$	Точное решение
0.1	1.01000	1.01005	0.6	1.42840	1.43333
0.2	1.04050	1.04081	0.7	1.62438	1.63232
0.3	1.09336	1.09417	0.8	1.88396	1.89648
0.4	1.17186	1.17351	0.9	2.22835	2.24791
0.5	1.28108	1.28403	1.0	2.68783	2.71828

Как видно из таблицы, решение оказалось найдено с точностью  $\varepsilon \approx 3 \cdot 10^{-2}$ .

## § 14.4. Метод Эйлера

1. Геометрическая интерпретация метода Эйлера. Простейшим и исторически первым численным методом решения задачи Коши является метод Эйлера. Его можно получить, если в приближенном равенстве (14.44) оставить только два первых слагаемых (т.е. взять  $p = 1$ ). Тогда формула (14.44) примет вид

$$y_{n+1} = y_n + hf(t_n, y_n). \quad (14.46)$$

Геометрическая интерпретация одного шага метода Эйлера заключается в аппроксимации решения на отрезке  $[t_n, t_{n+1}]$  касательной  $y = y_n + y'(t_n)(t - t_n)$ , проведенной в точке  $(t_n, y_n)$  к интегральной кривой, проходящей через эту точку (рис. 14.7).

Таким образом, после выполнения  $N$  шагов неизвестная интегральная кривая заменяется ломаной линией (ломаной Эйлера), для которой угловой коэффициент  $k_n$  очередного  $n$ -го звена равен значению  $f(t_n, y_n)$  (рис. 14.8).

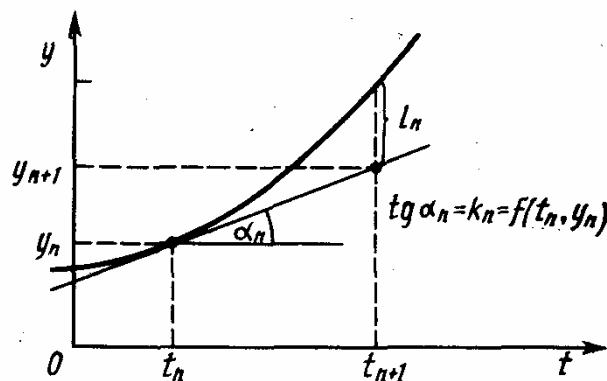


Рис. 14.7

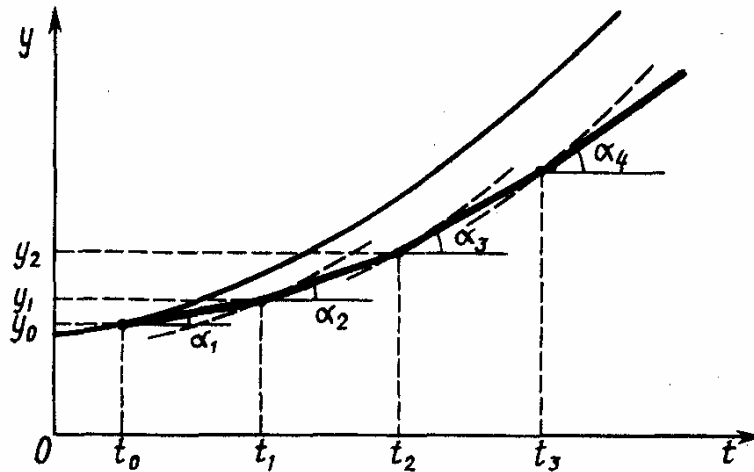


Рис. 14.8

Как уже было отмечено в § 14.2, метод Эйлера представляет явный одношаговый метод. Для него погрешность аппроксимации имеет вид  $\psi_n = \frac{h}{2} y''(\xi_n)$ .

**2. Устойчивость.** Докажем, что метод Эйлера устойчив на конечном отрезке (см. определение устойчивости в § 14.2). Предварительно установим справедливость следующего вспомогательного утверждения.

**Лемма 14.1.** Пусть  $z^h$  — неотрицательная сеточная функция, удовлетворяющая для всех  $n \geq 0$  неравенству  $z_{n+1} \leq (1 + \alpha)z_n + \beta_n$ , где  $\alpha \geq 0$ ,  $\beta_n \geq 0$ . Тогда при всех  $n \geq 0$  справедлива оценка

$$z_n \leq e^{n\alpha} \left( z_0 + \sum_{k=0}^{n-1} \beta_k \right). \quad (14.47)$$

□ Справедливость неравенства (14.47) установим методом индукции. При  $n = 0$  оно превращается в очевидное:  $z_0 \leq z_0$ .

Пусть теперь неравенство (14.47) выполнено при некотором  $n = m$ . Тогда, используя оценки  $1 + \alpha \leq e^\alpha$  и  $1 \leq e^{(m+1)\alpha}$ , получим следующую цепочку неравенств:

$$\begin{aligned} z_{m+1} &\leq (1 + \alpha)z_m + \beta_m \leq e^\alpha z_m + e^{(m+1)\alpha} \beta_m \leq \\ &\leq e^\alpha e^{m\alpha} \left( z_0 + \sum_{k=0}^{m-1} \beta_k \right) + e^{(m+1)\alpha} \beta_m = e^{(m+1)\alpha} \left( z_0 + \sum_{k=0}^m \beta_k \right), \end{aligned}$$

т.е. неравенство (14.47) верно и при  $n = m + 1$ . Итак, оно верно при всех  $n$ . ■

Пусть теперь  $y^{*h}$  — решение возмущенной дискретной задачи Коши

$$y_{n+1}^* = y_n^* + h(f(t_n, y_n^*) + \psi_n), \quad (14.48)$$

$$y^{*h}(t_0) = y_0^*. \quad (14.49)$$

**Теорема 14.5.** Пусть функция  $f$  удовлетворяет условию  $|f'_y| \leq L$ . Тогда справедливо неравенство

$$\max_{0 \leq n \leq N} |y_n^* - y_n| \leq e^{L(T-t_0)} (|y_0^* - y_0| + h \sum_{k=0}^{N-1} |\psi_k|), \quad (14.50)$$

означающее, что метод Эйлера устойчив на конечном отрезке.

□ Вычитая из уравнения (14.48) уравнение (14.46) и пользуясь формулой конечных приращений Лагранжа

$$f(t_n, y_n^*) - f(t_n, y_n) = f'_y(t_n, \tilde{y}_n)(y_n^* - y_n),$$

получаем равенство

$$y_{n+1}^* - y_{n+1} = (1 + hf'_y(t_n, \tilde{y}_n))(y_n^* - y_n) + h\psi_n,$$

откуда следует

$$|y_{n+1}^* - y_{n+1}| \leq (1 + hL)|y_n^* - y_n| + h|\psi_n|. \quad (14.51)$$

Заметим теперь, что для  $z_n = |y_n^* - y_n|$ ,  $\alpha = hL$  и  $\beta_n = h|\psi_n|$  в силу (14.51) справедливо неравенство  $z_{n+1} \leq (1 + \alpha)z_n + \beta_n$ . Согласно лемме 14.1, имеем  $|y_n^* - y_n| \leq e^{nhL}(|y_0^* - y_0| + \sum_{k=0}^{n-1} |\psi_k|h)$ . Учитывая, что  $nh \leq Nh = T - t_0$ , приходим к неравенству (14.50). ■

**3. Оценка погрешности.** Так как метод Эйлера устойчив на конечном отрезке и имеет первый порядок аппроксимации (см. пример 14.9), то из теоремы 14.4 следует, что он сходится с первым порядком точности. Точнее, верна следующая теорема.

**Теорема 14.6.** Пусть функция  $f$  удовлетворяет условию  $|f'_y| \leq L$ . Тогда для метода Эйлера справедлива такая оценка глобальной погрешности:

$$\max_{0 \leq n \leq N} |y(t_n) - y_n| \leq C(T)h, \quad (14.52)$$

$$\text{где } C(T) = e^{L(T-t_0)} (T-t_0)M_2/2, \quad M_2 = \max_{[t_0, T]} |y''(t)|.$$

Приведем доказательство теоремы, не использующее теорему 14.4.

□ Пусть  $\psi_n$  — погрешность аппроксимации. Перепишем ее определение (14.33) в виде

$$y(t_{n+1}) = y(t_n) + h(f(t_n, y(t_n)) + \psi_n).$$

Полагая  $y_n^* = y(t_n)$ , замечаем, что сеточная функция  $y^{*h}$  является решением дискретной задачи Коши (14.48), (14.49), где  $y_0^* = y_0$ . Тогда в силу теоремы 14.5 справедлива оценка

$$\max_{0 \leq n \leq N} |y(t_n) - y_n| \leq e^{L(T-t_0)} \sum_{n=0}^{N-1} |\psi_n| h.$$

Учитывая, что  $\sum_{n=0}^{N-1} |\psi_n| h \leq \max_{0 \leq n < N} |\psi_n| (T - t_0)$ , и используя оценку

(14.34) для погрешности аппроксимации, получим неравенство (14.52). ■

**Пример 14.13.** Найдём численное решение задачи Коши  $y' = 2ty$ ,  $y(0) = 1$ , на отрезке  $[0, 1]$ , используя метод Эйлера. Заметим, что та же задача другим методом была решена в примере 14.12.

В данном случае расчетная формула (14.46) принимает вид

$$y_{n+1} = y_n + h2t_n y_n = (1 + 2ht_n) y_n. \quad (14.53)$$

Полученные с помощью этой формулы для значений шагов  $h = 0.1$ ,  $h = 0.01$  и  $h = 0.001$  приближенные решения приведены в табл. 14.2. Для сравнения в последнем столбце даны значения точного решения  $y(t) = e^{t^2}$ . Нижняя строка таблицы содержит значения абсолютной погрешности  $E(h)$ . Как и следовало ожидать, при уменьшении шага в 10 раз погрешность уменьшается также примерно в 10 раз.

Т а б л и ц а 14.2

$t$	Метод Эйлера; $h = 0.1$	Метод Эйлера; $h = 0.01$	Метод Эйлера; $h = 0.001$	Точное решение
0.1	1.00000	1.00903	1.00995	1.01005
0.2	1.02000	1.03868	1.04060	1.04081
0.3	1.06080	1.09071	1.09383	1.09417
0.4	1.12445	1.16835	1.17299	1.17351
0.5	1.21440	1.27659	1.28328	1.28403

$t$	Метод Эйлера; $h = 0.1$	Метод Эйлера; $h = 0.01$	Метод Эйлера; $h = 0.001$	Точное решение
0.6	1.33584	1.42277	1.43226	1.43333
0.7	1.49615	1.61733	1.63080	1.63232
0.8	1.70561	1.87513	1.89432	1.89648
0.9	1.97850	2.21724	2.24480	2.24791
1.0	2.33463	2.67379	2.71376	2.71828
$E(h)$	$3.9 \cdot 10^{-1}$	$4.5 \cdot 10^{-2}$	$4.6 \cdot 10^{-3}$	—

4. Влияние вычислительной погрешности. Оценивая метод Эйлера необходимо учитывать, что при его реализации на ЭВМ неизбежно возникнут ошибки округления. В результате фактически вычисляемые значения  $y_n^*$  будут удовлетворять соотношению

$$y_{n+1}^* = y_n^* + hf(t_n, y_n^*) + \delta_n.$$

Величины  $\delta_n$  учитывают вклад погрешностей округления. Это соотношение можно рассматривать как возмущенное уравнение вида (14.48), в котором  $\psi_n = \delta_n/h$ . Тогда неравенство (14.50) дает следующую оценку влияния погрешностей округления:

$$\max_{0 \leq n \leq N} |y_n^* - y_n| \leq e^{L(T-t_0)} \sum_{n=0}^{N-1} |\delta_n| \approx e^{L(T-t_0)} N\delta. \quad (14.54)$$

Здесь  $\delta$  — некоторое среднее значение величины  $\delta_n$ , а  $N = (T - t_0)/h$ .

Таким образом, с учетом неравенств (14.52) и (14.54) получается следующая оценка погрешности фактически вычисляемых значений  $y_n^*$ :

$$\max_{0 \leq n \leq N} |y(t_n) - y_n^*| \lesssim \bar{E}_T(h) = e^{L(T-t_0)} (T - t_0) \left[ \frac{M_2}{2} \cdot h + \frac{\delta}{h} \right].$$

Схематически график функции  $\bar{E}_T(h)$  приведен на рис. 14.9.

Оказывается, что полная погрешность убывает только лишь при уменьшении шага  $h$  до некоторого значения  $h_{\text{опт}}$ . Достижимая точность метода ограничена снизу величиной  $E_{\text{мин}}$  и попытка увеличить точность за счет уменьшения шага  $h$  при  $h < h_{\text{опт}}$  приводит лишь к резкому росту погрешности.

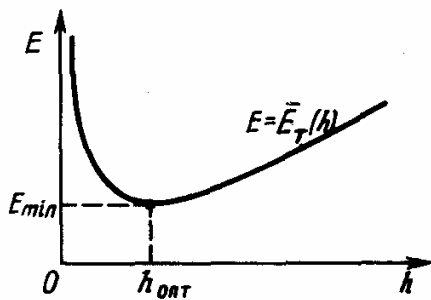


Рис. 14.9

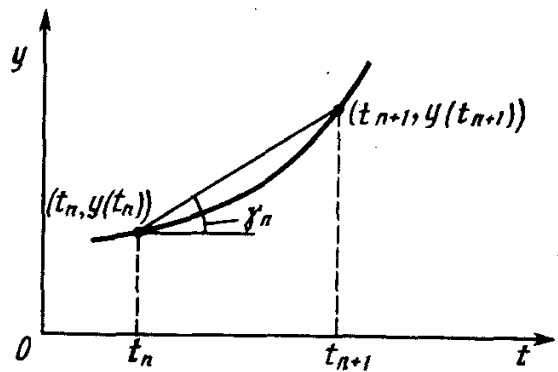


Рис. 14.10

Значение  $h_{\text{опт}}$ , как правило, бывает очень трудно определить заранее. Однако если очень высокая точность не нужна, то необходимый для ее достижения шаг  $h$  обычно бывает много больше  $h_{\text{опт}}$ .

Если же требуется высокая точность решения, то достичь ее с помощью метода Эйлера нельзя, даже если пойти на значительные затраты машинного времени (неизбежные при расчете с малым значением шага  $h$ ). Необходимо иметь в своем распоряжении методы, имеющие более высокий порядок точности и позволяющие вести расчет со сравнительно крупным шагом  $h$ .

### § 14.5. Модификации метода Эйлера второго порядка точности

Медленная сходимость метода Эйлера (его погрешность убывает пропорционально лишь первой степени  $h$ ) является серьезным препятствием для использования его на практике. Из рис. 14.7 видно, что уже один шаг по касательной к интегральной кривой приводит к значительной величине локальной погрешности  $l_n$ . Можно ли так подправить расчетную формулу метода, чтобы существенно уменьшить величину  $l_n$ ?

Пусть  $y(t)$  — решение дифференциального уравнения

$$y'(t) = f(t, y(t)), \quad (14.55)$$

удовлетворяющее условию  $y(t_n) = y_n$ . Далее, пусть

$$k_n = \frac{y(t_{n+1}) - y(t_n)}{h} = \text{tg } \gamma_n \quad (14.56)$$

— угловой коэффициент секущей, проходящей через точки  $(t_n, y(t_n))$  и  $(t_{n+1}, y(t_{n+1}))$  графика функции  $y(t)$  (рис. 14.10).



Ясно, что "метод", состоящий в вычислении по формуле

$$y_{n+1} = y_n + hk_n, \quad (14.57)$$

имеет нулевую локальную погрешность. Для того чтобы воспользоваться этой формулой, нужно лишь "научиться вычислять значение  $k_n$ ".

Интегрируя обе части уравнения (14.55) по  $t$  от  $t_n$  до  $t_{n+1}$  и используя формулу Ньютона—Лейбница  $\int_{t_n}^{t_{n+1}} y'(t) dt = y(t_{n+1}) - y(t_n)$ , приходим к равенству

$$y(t_{n+1}) - y(t_n) = \int_{t_n}^{t_{n+1}} f(t, y(t)) dt. \quad (14.58)$$

Из равенств (14.56) и (14.58) следует, что

$$k_n = \frac{1}{h} \int_{t_n}^{t_{n+1}} f(t, y(t)) dt. \quad (14.59)$$

Заметим теперь, что применение для приближенного вычисления интеграла, стоящего в правой части выражения (14.59), формулы левых прямоугольников  $\int_{t_n}^{t_{n+1}} f(t, y(t)) dt \approx hf(t_n, y(t_n))$  немедленно приводит от (14.57) к методу Эйлера (14.46).

Известно (см. гл. 13), что больший порядок точности имеет формула трапеций

$$\int_{t_n}^{t_{n+1}} f(t, y(t)) dt \approx \frac{h}{2} (f(t_n, y(t_n)) + f(t_{n+1}, y(t_{n+1}))).$$

Непосредственное ее применение к вычислению  $k_n$  приводит к правилу трапеций:

$$y_{n+1} = y_n + \frac{h}{2} (f(t_n, y_n) + f(t_{n+1}, y_{n+1})) \quad (14.60)$$

(ср. с (14.25)). Этот метод имеет второй порядок точности, но является неявным. Поэтому его реализация связана с необходимостью решения относительно  $y_{n+1}$  нелинейного уравнения (14.60).

Построим на основе правила трапеций явный метод. Для этого подставим в правую часть формулы (14.60) значение  $y_{n+1}$ , "предсказываемое" методом Эйлера. В результате получается метод

$$y_{n+1} = y_n + \frac{h}{2} (f(t_n, y_n) + f(t_{n+1}, y_n + hf(t_n, y_n))), \quad (14.61)$$

который называют *методом Эйлера—Коши* (или *методом Хьюна*).

Геометрическая иллюстрация этого метода представлена на рис. 14.11. Вычисления разбивают на два этапа. На первом этапе (этапе прогноза) в соответствии с методом Эйлера  $y_{n+1}^{(0)} = y_n + hk_n^{(1)}$ ,  $k_n^{(1)} = f(t_n, y_n)$  вычисляют грубое приближение к значению  $y(t_{n+1})$ . В точке  $(t_{n+1}, y_{n+1}^{(0)})$  определяют угловой коэффициент  $k_n^{(2)} = f(t_{n+1}, y_{n+1}^{(0)})$ . На втором этапе (этапе коррекции) вычисляют усредненное значение углового коэффициента  $k_n = (k_n^{(1)} + k_n^{(2)})/2$ . Уточненное значение  $y_{n+1}$  находят по формуле  $y_{n+1} = y_n + hk_n$ , что соответствует шагу по прямой, проходящей через точку  $(t_n, y_n)$  и имеющей угловой коэффициент, равный  $k_n$ .

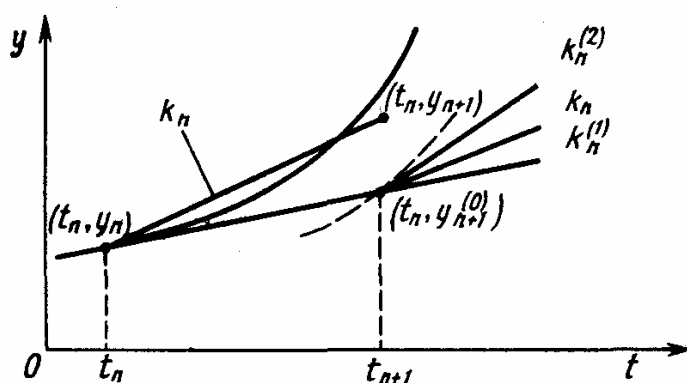


Рис. 14.11

**З а м е ч а н и е.** Метод Эйлера—Коши относится к классу *методов прогноза и коррекции* (иначе говоря, *методов типа предиктор—корректор*<sup>1</sup>).

<sup>1</sup> От англ. to predict — "предсказывать", "прогнозировать"; to correct — "исправлять", "корректировать".

Метод (14.61), который можно рассматривать как модификацию метода Эйлера, имеет второй порядок точности. Еще одну модификацию второго порядка точности можно получить с помощью формулы (центральных) прямоугольников

$$\int_{t_n}^{t_{n+1}} f(t, y(t)) dt \approx hf(t_{n+1/2}, y(t_{n+1/2})), \quad t_{n+1/2} = t_n + h/2,$$

если для приближенного вычисления значения  $y(t_{n+1/2})$  применить метод Эйлера. В результате получим расчетные формулы усовершенствованного метода Эйлера

$$y_{n+1/2} = y_n + \frac{h}{2} k_n^{(1)}, \quad k_n^{(1)} = f(t_n, y_n), \quad (14.62)$$

$$y_{n+1} = y_n + hk_n, \quad k_n = f(t_{n+1/2}, y_{n+1/2}).$$

Геометрическая иллюстрация этого метода приведена на рис. 14.12.

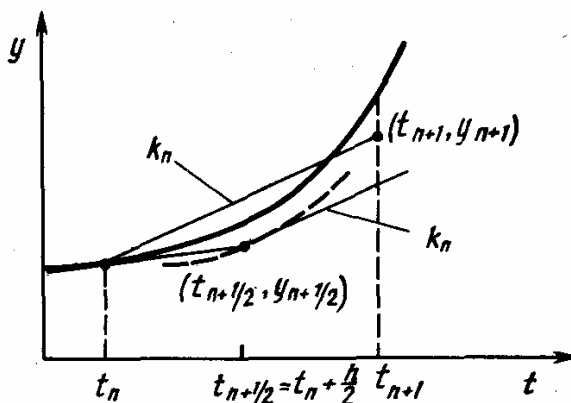


Рис. 14.12

**Пример 14.14.** Применим рассмотренные в этом параграфе методы для численного решения задачи (14.45) с шагом  $h = 0.1$ .

Расчетная формула метода Эйлера—Коши принимает вид

$$\begin{aligned} y_{n+1} &= y_n + \frac{h}{2} (2t_n y_n + \\ &+ 2t_{n+1}(y_n + h2t_n y_n)) = \quad (14.63) \\ &= y_n [1 + h(t_n + t_{n+1} + \\ &+ 2ht_n t_{n+1})]. \end{aligned}$$

Вычисления усовершенствованного метода Эйлера производим по формуле

$$y_{n+1} = y_n + 2h(t_n + \frac{h}{2})(y_n + \frac{h}{2} \cdot 2t_n y_n) = y_n(1 + h(2t_n + h)(1 + ht_n)). \quad (14.64)$$

Правило трапеций (14.60) приводит к уравнению

$$y_{n+1} = y_n + \frac{h}{2} (2t_n y_n + 2t_{n+1} y_{n+1}),$$

которое в данном случае линейно и легко разрешается относительно  $y_{n+1}$ :

$$y_{n+1} = y_n(1 + ht_n)(1 - ht_{n+1}). \quad (14.65)$$

Результаты вычислений по формулам (14.63), (14.64) и (14.65) приведены в табл. 14.3. Там же для сравнения представлены значения решения  $y(t) = e^{t^2}$ . Нижняя строка таблицы содержит величину абсолютной погрешности  $E(h)$ .

Т а б л и ц а 14.3

$t_n$	Метод Эйлера-Коши; $h = 0.1$	Усовершенствованный метод Эйлера; $h = 0.1$	Правило трапеций; $h = 0.1$	Точное решение
0.1	1.01000	1.01000	1.01010	1.01005
0.2	1.04070	1.04060	1.04102	1.04081
0.3	1.09399	1.09367	1.09468	1.09417
0.4	1.17319	1.17253	1.17450	1.17351
0.5	1.28347	1.28228	1.28577	1.28403
0.6	1.43236	1.43038	1.43624	1.43333
0.7	1.63059	1.62749	1.63700	1.63232
0.8	1.89345	1.88870	1.90390	1.89648
0.9	2.24260	2.23546	2.25958	2.24791
1.0	2.70906	2.69843	2.73660	2.71828
$E(h)$	$0.93 \cdot 10^{-2}$	$2.0 \cdot 10^{-2}$	$1.9 \cdot 10^{-2}$	-

Как видно из сравнения табл. 14.3 с табл. 14.2, проведенные в этом параграфе модификации метода Эйлера действительно привели к повышению точности.

## § 14.6. Методы Рунге—Кутты

Наиболее популярными среди классических явных одношаговых методов являются методы Рунге — Кутты<sup>1</sup>. Методы Эйлера, Эйлера — Коши и усовершенствованный метод Эйлера можно рассматривать как простейших представителей этого класса методов.

**1. Вывод расчетных формул.** Поясним вывод расчетных формул метода Рунге—Кутты. Пусть (как и в § 14.5)  $y(t)$  — решение диффе-

<sup>1</sup> В.М.Кутта (1867—1944) — немецкий математик.

ренциального уравнения  $y' = f(t, y)$ , удовлетворяющее условию  $y(t_n) = y_n$ . Запишем равенство (14.58) в следующем виде:

$$y(t_{n+1}) = y(t_n) + \int_{t_n}^{t_{n+1}} f(t, y(t)) dt. \quad (14.66)$$

Если бы входящий в это равенство интеграл можно было вычислить точно, то получилась бы простая формула, позволяющая последовательно вычислить значения решения в узлах сетки. Поскольку в действительности это невозможно, попробуем получить приближенную формулу, заменив интеграл квадратурной суммой (см. гл. 13).

Введем на отрезке  $[t_n, t_{n+1}]$   $m$  вспомогательных узлов  $t_n^{(1)} = t_n + \alpha_1 h$ ,  $t_n^{(2)} = t_n + \alpha_2 h, \dots, t_n^{(m)} = t_n + \alpha_m h$ , где  $0 = \alpha_1 \leq \alpha_2 \leq \dots \leq \alpha_m \leq 1$ . Заметим, что  $t_n^{(1)} = t_n$ ,  $t_n^{(m)} \leq t_{n+1}$ . Заменяя входящий в равенство (14.66) интеграл квадратурной суммой с узлами  $t_n^{(1)}, \dots, t_n^{(m)}$ , получаем приближенное равенство

$$y(t_{n+1}) \approx y(t_n) + h \sum_{i=1}^m c_i f(t_n^{(i)}, y(t_n^{(i)})). \quad (14.67)$$

Однако воспользоваться равенством (14.67) для вычисления  $y(t_{n+1})$  нельзя, так как значения функции  $y$  в точках  $t_n^{(i)}$  для  $i = 2, 3, \dots, m$  неизвестны. Чтобы найти эти значения, запишем равенства

$$y(t_n^{(i)}) = y(t_n) + \int_{t_n}^{t_n^{(i)}} f(t, y(t)) dt \quad (i = 2, 3, \dots, m), \quad (14.68)$$

аналогичные равенству (14.66). Заменяя для каждого  $i$  входящий в формулу (14.68) интеграл соответствующей ему квадратурной формулой с узлами  $t_n^{(1)}, t_n^{(2)}, \dots, t_n^{(i-1)}$ , придем к приближенным равенствам

$$\begin{aligned} y(t_n^{(2)}) &\approx y(t_n) + h\beta_{21}f(t_n^{(1)}, y(t_n^{(1)})), \\ y(t_n^{(3)}) &\approx y(t_n) + h(\beta_{31}f(t_n^{(1)}, y(t_n^{(1)})) + \beta_{32}f(t_n^{(2)}, y(t_n^{(2)}))), \\ &\dots\dots\dots \\ y(t_n^{(i)}) &\approx y(t_n) + h\sum_{j=1}^{i-1}\beta_{ij}f(t_n^{(j)}, y(t_n^{(j)})), \\ &\dots\dots\dots \\ y(t_n^{(m)}) &\approx y(t_n) + h\sum_{j=1}^{m-1}\beta_{mj}f(t_n^{(j)}, y(t_n^{(j)})), \end{aligned}$$

позволяющим последовательно вычислять приближения к значениям  $y(t_n^{(2)}), \dots, y(t_n^{(m)})$ .

Обозначим теперь через  $y_n^{(i)}$  вспомогательные величины, имеющие смысл приближений к значениям  $y(t_n^{(i)})$ ; пусть  $k_n^{(i)} = f(t_n^{(i)}, y_n^{(i)})$  — приближение к значению углового коэффициента  $k$  в точке  $t_n^{(i)}$ . Тогда расчетные формулы примут вид

$$\begin{aligned} y_{n+1} &= y_n + h k_n, & k_n &= \sum_{i=1}^m c_i k_n^{(i)}, \\ k_n^{(1)} &= f(t_n^{(1)}, y_n^{(1)}), & y_n^{(1)} &= y_n, \\ k_n^{(2)} &= f(t_n^{(2)}, y_n^{(2)}), & y_n^{(2)} &= y_n + h \beta_{21} k_n^{(1)}, \\ k_n^{(3)} &= f(t_n^{(3)}, y_n^{(3)}), & y_n^{(3)} &= y_n + h(\beta_{31} k_n^{(1)} + \beta_{32} k_n^{(2)}), \\ &\dots\dots\dots \\ k_n^{(m)} &= f(t_n^{(m)}, y_n^{(m)}), & y_n^{(m)} &= y_n + h \sum_{j=1}^{m-1} \beta_{mj} k_n^{(j)}. \end{aligned}$$

Часто из этих формул исключают вспомогательные величины  $y_n^{(i)}$  и записывают формулы так:

$$\begin{aligned} y_{n+1} &= y_n + h k_n, & k_n &= \sum_{i=1}^m c_i k_n^{(i)}, \\ k_n^{(1)} &= f(t_n, y_n), \\ k_n^{(2)} &= f(t_n + \alpha_2 h, y_n + h \beta_{21} k_n^{(1)}), \\ k_n^{(3)} &= f(t_n + \alpha_3 h, y_n + h(\beta_{31} k_n^{(1)} + \beta_{32} k_n^{(2)})), \\ &\dots\dots\dots \\ k_n^{(m)} &= f(t_n + \alpha_m h, y_n + h \sum_{j=1}^{m-1} \beta_{mj} k_n^{(j)}). \end{aligned}$$

Заметим, что выведенные формулы задают явный одношаговый метод вида  $y_{n+1} = y_n + h \Phi(t_n, y_n, h)$ , где для вычисления значений функции  $\Phi(t_n, y_n, h) = \sum_{i=1}^m c_i k_n^{(i)}$  используются значения правой части  $f$  в  $m$  вспомогательных точках. Поэтому этот метод называют *явным  $m$ -этапным методом Рунге—Кутты*.

Выбор конкретных значений параметров  $c_i, \alpha_i, \beta_{ij}$  осуществляется исходя из различных соображений. Естественно, что одним из основных является желание сделать порядок аппроксимации  $p$  максимально возможным.

**2. Устойчивость и сходимость.** Следующая теорема позволяет в дальнейшем называть методы Рунге—Кутты, имеющие  $p$ -й порядок аппроксимации, методами  $p$ -го порядка точности.

**Т е о р е м а 14.7.** Пусть правая часть дифференциального уравнения удовлетворяет условию  $|f'_y| \leq L$ . Тогда всякий явный  $m$ -этапный метод Рунге—Кутты устойчив на конечном отрезке.

**С л е д с т в и е.** Пусть выполнено условие  $|f'_y| \leq L$ . Тогда если явный  $m$ -этапный метод Рунге—Кутты имеет  $p$ -й порядок аппроксимации, то он сходится с  $p$ -м порядком точности.

Справедливость следствия вытекает из теоремы 14.4.

**3. Семейство явных двухэтапных методов.** Выведем расчетные формулы семейства явных двухэтапных методов Рунге—Кутты второго порядка точности. Запишем формулы явного двухэтапного метода

$$y_{n+1} = y_n + h (c_1 k_n^{(1)} + c_2 k_n^{(2)}),$$

$$k_n^{(1)} = f(t_n, y_n), \quad k_n^{(2)} = f(t_n + \alpha h, y_n + h\beta k_n^{(1)})$$

в виде

$$\frac{y_{n+1} - y_n}{h} = c_1 f(t_n, y_n) + c_2 f(t_n + \alpha h, y_n + h\beta f(t_n, y_n)).$$

Параметрами этого метода являются величины  $c_1, c_2, \alpha, \beta$ .

Представим погрешность аппроксимации

$$\psi = \frac{y(t+h) - y(t)}{h} - c_1 f(t, y) - c_2 f(t + \alpha h, y + h\beta f(t, y)),$$

(где  $t = t_n, y = y(t_n), y(t)$  — решение дифференциального уравнения  $y' = f(t, y)$ ) в виде разложения по степеням  $h$ .

Формула Тейлора

$$y(t+h) = y(t) + y'(t)h + \frac{y''(t)}{2} h^2 + O(h^3)$$

с учетом равенств  $y' = f, y'' = f'_t + f'_y f$  (см. (14.42)) дает формулу

$$\frac{y(t+h) - y(t)}{h} = f + \frac{1}{2} (f'_t + f'_y f) h + O(h^2)$$

(аргументы  $t, y$  у функции  $f$  и ее частных производных  $f'_t, f'_y$  опускаем).

Представим значение функции  $f$  в точке  $(t + \alpha h, y + h\beta f)$ , используя формулу Тейлора для функции двух переменных с центром в точке  $(t, y)$ :

$$f(t + \alpha h, y + h\beta f) = f(t, y) + f'_t \alpha h + f'_y h\beta f + O(h^2).$$

Таким образом,

$$\psi = (1 - c_1 - c_2)f + [(1/2 - c_2\alpha)f'_t + (1/2 - c_2\beta)f'_y f] h + O(h^2).$$

Если потребовать, чтобы выполнялись условия  $c_1 + c_2 = 1$ ,  $c_2\alpha = 1/2$ ,  $c_2\beta = 1/2$  (что эквивалентно выбору  $c_1 = 1 - \frac{1}{2\alpha}$ ,  $c_2 = \frac{1}{2\alpha}$ ,  $\beta = \alpha$ ), то первые два слагаемых в формуле для  $\psi$  обратятся в нуль, и поэтому метод будет иметь второй порядок аппроксимации.

Итак (с учетом следствия из теоремы 14.7), можно утверждать, что при любом  $\alpha \in (0, 1)$  метод

$$y_{n+1} = y_n + h \left[ \left(1 - \frac{1}{2\alpha}\right) f(t_n, y_n) + \frac{1}{2\alpha} f(t_n + \alpha h, y_n + \alpha h f(t_n, y_n)) \right] \quad (14.69)$$

имеет второй порядок точности.

Заметим, что при  $\alpha = 1$  формула (14.69) дает метод Эйлера—Коши, а при  $\alpha = 1/2$  — усовершенствованный метод Эйлера (см. § 14.5).

**4. Метод Рунге—Кутты четвертого порядка точности.** Наиболее известным из методов Рунге—Кутты является классический 4-этапный метод четвертого порядка точности:

$$\begin{aligned} y_{n+1} &= y_n + h k_n, \quad k_n = \frac{1}{6} (k_n^{(1)} + 2k_n^{(2)} + 2k_n^{(3)} + k_n^{(4)}), \\ k_n^{(1)} &= f(t_n, y_n), \quad k_n^{(2)} = f\left(t_n + \frac{h}{2}, y_n + \frac{h}{2} k_n^{(1)}\right), \\ k_n^{(3)} &= f\left(t_n + \frac{h}{2}, y_n + \frac{h}{2} k_n^{(2)}\right), \quad k_n^{(4)} = f(t_n + h, y_n + h k_n^{(3)}). \end{aligned} \quad (14.70)$$

Этот метод весьма прост и, как показывает практика, довольно эффективен в обычных расчетах, когда отрезок  $[t_0, T]$  не очень велик и нужна сравнительно невысокая точность.

**З а м е ч а н и е.** Применение метода (14.70) к решению задачи о вычислении интеграла (14.36) порождает формулу Симпсона

$$y_{n+1} = y_n + \frac{h}{6} (f(t_n) + 4f(t_{n+1/2}) + f(t_{n+1})).$$



Таким образом, классический метод Рунге—Кутты четвертого порядка точности (14.70) можно рассматривать как аналог формулы Симпсона, отвечающий решению задачи Коши.

**Пример 14.15.** Продемонстрируем работу метода Рунге—Кутты четвертого порядка точности применительно к решению задачи Коши (14.45).

В этом случае расчетные формулы принимают вид

$$y_{n+1} = y_n + hk_n, \quad k_n = \frac{1}{6} (k_n^{(1)} + 2k_n^{(2)} + 2k_n^{(3)} + k_n^{(4)}),$$

$$k_n^{(1)} = 2t_n y_n, \quad k_n^{(2)} = 2 \left( t_n + \frac{h}{2} \right) \left( y_n + \frac{h}{2} k_n^{(1)} \right),$$

$$k_n^{(3)} = 2 \left( t_n + \frac{h}{2} \right) \left( y_n + \frac{h}{2} k_n^{(2)} \right), \quad k_n^{(4)} = 2(t_n + h) \left( y_n + h k_n^{(3)} \right).$$

Найденные с шагом  $h = 0.1$  приближенные значения решения  $y_n$  и их погрешности  $\varepsilon_n$  приведены в табл. 14.4.

Т а б л и ц а 14.4

$t_n$	$y_n$	$\varepsilon_n$	$t_n$	$y_n$	$\varepsilon_n$
0.1	1.010050167	$10^{-9}$	0.6	1.433328994	$5 \cdot 10^{-7}$
0.2	1.040810770	$4 \cdot 10^{-9}$	0.7	1.632315187	$2 \cdot 10^{-6}$
0.3	1.094174265	$2 \cdot 10^{-8}$	0.8	1.896478467	$3 \cdot 10^{-6}$
0.4	1.173510814	$6 \cdot 10^{-8}$	0.9	2.247902590	$6 \cdot 10^{-6}$
0.5	1.284025256	$2 \cdot 10^{-7}$	1.0	2.718270175	$2 \cdot 10^{-5}$

**5. Обсуждение методов Рунге—Кутты.** Методы Рунге—Кутты имеют несколько достоинств, определивших их популярность среди значительного числа исследователей. Эти методы легко программируются<sup>1</sup>. Они обладают достаточными для широкого круга задач свойствами точности и устойчивости. Эти методы (как и все одношаговые методы) являются самостартующими и позволяют на любом этапе вычислений легко изменять шаг интегрирования.

Увеличивая число  $m$  вспомогательных точек, можно построить методы Рунге—Кутты любого порядка точности  $p$ . Однако уже при

<sup>1</sup> Это очень важно, если отсутствуют или по каким-либо причинам недоступны соответствующие стандартные программы. Если же используются развитые пакеты прикладных программ, то сложность программирования метода не интересует пользователя, поскольку он обращает внимание на другие свойства метода.

$p > 5$  эти методы используются довольно редко. Это объясняется как чрезмерной громоздкостью получающихся вычислительных формул, так и тем, что преимущества методов высокого порядка точности  $p$  над методами, в которых  $p = 4$  и  $p = 5$ , проявляются либо в тех задачах, где нужна очень высокая точность и используются ЭВМ высокой разрядности, либо в тех задачах, где решение очень гладкое. Кроме того, методы Рунге—Кутты высокого порядка точности  $p$  часто оказываются менее эффективными по сравнению с методами Адамса того же порядка точности (см. § 14.7).

**З а м е ч а н и е.** Кроме описанных выше классических явных методов Рунге—Кутты используются и более сложные в реализации неявные  $m$ -этапные методы Рунге—Кутты:

$$y_{n+1} = y_n + h k_n, \quad k_n = \sum_{i=1}^m c_i k_n^{(i)};$$

$$k_n^{(i)} = f(t_n + \alpha_i h, y_n + h \sum_{j=1}^m \beta_{ij} k_n^{(j)}), \quad i = 1, 2, \dots, m.$$

Эти методы имеют ряд преимуществ перед явными методами, однако это достигается за счет существенного усложнения вычислительного алгоритма, так как на каждом шаге необходимо решать систему  $m$  нелинейных уравнений. В настоящее время неявные методы Рунге—Кутты применяются в основном для решения так называемых жестких задач (см. § 14.11).

**6. Автоматический выбор шага.** Отметим, что в современных программах, реализующих методы Рунге—Кутты, обязательно используется некоторый алгоритм автоматического изменения шага интегрирования  $h_{n+1} = t_{n+1} - t_n$ .

Интуитивно ясно, что на участках плавного изменения решения счет можно вести с достаточно крупным шагом. В то же время на тех участках, где происходят резкие изменения поведения решения, необходимо выбирать мелкий шаг интегрирования. Обычно начальное значение шага  $h_1$  задает пользователь. Далее шаг интегрирования меняется в соответствии с величиной получаемой в ходе вычислений оценки локальной погрешности. Само по себе изменение шага  $h_n$  для методов Рунге—Кутты (впрочем, как и для всех других одношаговых методов) не представляет сложности. Действительная проблема состоит в том, как оценить локальную погрешность и выбрать очередной шаг интегрирования.

Один из распространенных подходов состоит в использовании правила Рунге (правила двойного пересчета). Пусть значение в точке  $t_n$

уже найдено и  $y(t)$  — решение уравнения  $y'(t) = f(t, y)$ , удовлетворяющее условию  $y(t_n) = y_n$ . Обозначим через  $y^{h_{n+1}}$  приближение  $y_{n+1}$  к значению  $y(t_{n+1})$ , найденное с помощью одношагового метода

$$y_{n+1} = y_n + h_{n+1} \Phi(t_n, y_n, y_{n+1}, h_{n+1}), \quad (14.71)$$

который имеет порядок точности, равный  $p$ . Можно показать, что для методов Рунге—Кутты локальная погрешность  $l_n = y(t_{n+1}) - y^{h_{n+1}}$  допускает представление

$$l_n = r(t_n, y_n) h_{n+1}^{p+1} + o(h_{n+1}^{p+1}),$$

где  $r(t, y)$  — непрерывная функция. Следовательно, при достаточно малых  $h_{n+1}$  справедливо приближенное равенство

$$y(t_{n+1}) - y^{h_{n+1}} \approx r(t_n, y_n) h_{n+1}^{p+1}. \quad (14.72)$$

Уменьшим теперь шаг интегрирования вдвое, положив  $h_{n+1/2} = h_{n+1}/2$ , и вычислим приближение к значению решения в точке  $t_{n+1}$  с помощью того же одношагового метода. Для этого потребуется выполнить уже два элементарных шага по формулам

$$\begin{aligned} y_{n+1/2} &= y_n + h_{n+1/2} \Phi(t_n, y_n, y_{n+1/2}, h_{n+1/2}), \\ y_{n+1} &= y_{n+1/2} + h_{n+1/2} \Phi(t_{n+1/2}, y_{n+1/2}, y_{n+1}, h_{n+1/2}). \end{aligned}$$

Полученное таким образом значение  $y^{h_{n+1/2}} = y_{n+1}$  будет, конечно, отличаться от значения, найденного по формуле (14.71). Достаточно ясно, что два шага величины  $h_{n+1/2}$  приведут здесь к локальной погрешности

$$y(t_{n+1}) - y^{h_{n+1/2}} \approx 2r(t_n, y_n) h_{n+1/2}^{p+1}. \quad (14.73)$$

Вычитая из равенства (14.72) равенство (14.73), получим формулу

$$y^{h_{n+1/2}} - y^{h_{n+1}} \approx (2^p - 1) 2r(t_n, y_n) h_{n+1/2}^{p+1}.$$

Сравнение ее с (14.73) приводит к приближенному равенству

$$y(t_{n+1}) - y^{h_{n+1/2}} \approx \frac{y^{h_{n+1/2}} - y^{h_{n+1}}}{2^p - 1} \quad (14.74)$$

Использование этой формулы для апостериорной оценки локальной погрешности значения  $y^{h_{n+1}/2}$  (которое в дальнейшем принимается за приближенное значение решения задачи Коши в точке  $t_{n+1}$ ) и называют *правилом Рунге*<sup>1</sup>. Заметим, что этот способ контроля точности приводит к увеличению времени счета примерно на 50%.

Существуют более экономичные методы оценки локальной погрешности, основанные на использовании для контроля точности двух различных методов Рунге — Кутты. В настоящее время одним из самых эффективных методов такого типа является метод Рунге—Кутты—Фельберга. В этом методе для оценки погрешности метода пятого порядка точности используются формулы метода четвертого порядка точности, причем на одном шаге требуется всего лишь шесть вычислений значений правой части<sup>2</sup>  $f$ .

После того как тем или иным способом оценена локальная ошибка, программа принимает решение о том, оставить ли шаг интегрирования прежним, уменьшить ли его вдвое или увеличить в два раза. Это происходит примерно по той же схеме, что и в адаптивных программах, предназначенных для вычисления определенных интегралов (см. § 13.5). Известно, что при оптимальном выборе шагов интегрирования абсолютные погрешности, приходящиеся на каждый из шагов, должны быть примерно равны (см. [9]). Этот результат учитывается при создании стандартных программ с автоматическим выбором шага.

**7. Влияние вычислительной погрешности.** Влияние погрешностей на результат вычислений с помощью явных методов Рунге — Кутты примерно таково же, как и для метода Эйлера (см. § 14.4). Однако для них  $\bar{E}_T(h) = C(T)(M_{p+1}h^p + \frac{\delta}{h})$ . Кроме того, высокая точность методов позволяет вести интегрирование со сравнительно большим шагом  $h \gg h_{\text{опт}}$  и поэтому влияние вычислительной погрешности обычно бывает несущественным.

---

<sup>1</sup> Отметим, что использование правила Рунге требует определенной осторожности, так как равенство (14.72) имеет место, вообще говоря, лишь при достаточно малом значении шага  $h_{n+1}$ .

<sup>2</sup> Более подробное описание этого метода можно найти в [86]. К сожалению, в приведенном в этой книге тексте соответствующей ФОРТРАН-программы имеются досадные опечатки.

## § 14.7. Лине́йные многошаговые методы.

### Методы Адамса

**1. Методы Адамса.** В одношаговых методах после того как найдено очередное значение  $y_n$  в точке  $t_n$ , значение  $y_{n-1}$  отбрасывают и уже не используют в последующих вычислениях. Естественно все же попытаться извлечь определенную пользу из информации о значениях решения  $y_{n-k+1}, \dots, y_{n-1}, y_n$  не в одной, а в  $k$  предыдущих точках  $t_{n-k+1}, \dots, t_{n-1}, t_n$ , т.е. применить многошаговый метод.

Среди многошаговых методов наибольшее распространение в практике вычислений получили *методы Адамса*<sup>1</sup>

$$\frac{y_{n+1} - y_n}{h} = \sum_{j=0}^k \beta_j f_{n+1-j}. \quad (14.75)$$

Здесь  $\beta_0, \beta_1, \dots, \beta_k$  — числовые коэффициенты,  $f_{n+1-j} = f(t_{n+1-j}, y_{n+1-j})$ . Уравнение (14.75) позволяет найти новое значение  $y_{n+1}$ , используя найденные ранее значения  $y_n, y_{n-1}, \dots, y_{n-k+1}$ . Поэтому предварительно требуется задание  $k$  начальных значений  $y_0, y_1, \dots, y_{k-1}$ .

В случае  $\beta_0 = 0$  метод Адамса является явным, так как значение  $y_{n+1}$  выражается через найденные ранее значения по явной формуле

$$y_{n+1} = y_n + h \sum_{j=1}^k \beta_j f_{n+1-j}. \quad (14.76)$$

Если же  $\beta_0 \neq 0$ , то для нахождения  $y_{n+1}$  приходится решать нелинейное уравнение

$$y_{n+1} = h\beta_0 f(t_{n+1}, y_{n+1}) + g_n, \quad (14.77)$$

где  $g_n = y_n + h \sum_{j=1}^k \beta_j f_{n+1-j}$  — известное значение. Поэтому при  $\beta_0 \neq 0$  метод Адамса (14.75) является неявным.

Существуют различные способы вывода формул (14.75). Приведем два из них. Воспользуемся, как и в предыдущем параграфе, равенством

$$y(t_{n+1}) = y(t_n) + \int_{t_n}^{t_{n+1}} f(t, y(t)) dt. \quad (14.78)$$

---

<sup>1</sup> Джон Кауч Адамс (1819 — 1892) — английский астроном и математик. Метод типа (14.75) был разработан им в 1855 г. по просьбе известного английского специалиста по внешней баллистике Башфорта.

Заменяем приближенно функцию  $F(t) \equiv f(t, y(t))$  интерполяционным многочленом  $(k-1)$ -й степени  $P_{k-1}(t)$ , принимающим значения  $f_n, f_{n-1}, \dots, f_{n-k+1}$  в тех узлах  $t_n, t_{n-1}, \dots, t_{n-k+1}$ , где значения сеточной функции  $y^h$  уже найдены. Интегрирование этого многочлена дает приближенное равенство

$$\int_{t_n}^{t_{n+1}} f(t, y(t)) dt \approx \int_{t_n}^{t_{n+1}} P_{k-1}(t) dt = h \sum_{j=1}^k \beta_j f_{n+1-j}. \quad (14.79)$$

В результате от (14.78) приходим к формуле (14.76), соответствующей явному  $k$ -шаговому методу Адамса—Башфорта.

**З а м е ч а н и е.** Так как многочлен  $P_{k-1}$  используется для приближения функции  $F$  вне отрезка, на котором известны ее значения, то в действительности равенство (14.79) основано на экстраполяции. Поэтому соответствующий метод называют еще *экстраполяционным методом Адамса*.

Если же в интеграле, входящем в равенство (14.78), заменить подынтегральную функцию интерполяционным многочленом  $k$ -й степени  $Q_k(t)$ , совпадающим со значениями  $f_{n+1-k}, \dots, f_n, f_{n+1}$  в узлах  $t_{n+1-k}, \dots, t_n, t_{n+1}$ , то получится формула

$$y_{n+1} = y_n + h \sum_{j=0}^k \beta_j f_{n+1-j}, \quad (14.80)$$

соответствующая  $k$ -шаговому методу Адамса — Моултона. Заметим, что этот метод — неявный.

**З а м е ч а н и е.** Метод (14.80) принято называть также *интерполяционным методом Адамса*.

Выведем формулы двухшагового метода Адамса—Башфорта и одношагового метода Адамса—Моултона.

Интерполяционные многочлены  $P_1(t)$  и  $Q_1(t)$  таковы:

$$\begin{aligned} P_1(t) &= f_{n-1}(t_n - t)/h + f_n(t - t_{n-1})/h, \\ Q_1(t) &= f_n(t_{n+1} - t)/h + f_{n+1}(t - t_n)/h. \end{aligned}$$

Их интегрирование по  $t$  дает следующие значения:

$$\int_{t_n}^{t_{n+1}} P_1(t) dt = h \left( \frac{3}{2} f_n - \frac{1}{2} f_{n-1} \right), \quad \int_{t_n}^{t_{n+1}} Q_1(t) dt = h \left( \frac{1}{2} f_{n+1} + \frac{1}{2} f_n \right).$$

Таким образом, двухшаговая формула Адамса—Башфорта имеет вид

$$y_{n+1} = y_n + \frac{h}{2} (3f_n - f_{n-1}),$$

а одношаговая формула Адамса—Моултона — вид

$$y_{n+1} = y_n + \frac{h}{2} (f_{n+1} + f_n).$$

**Предложение 14.1.** Пусть решение задачи Коши  $y(t)$  непрерывно дифференцируемо  $k$  раз на отрезке  $[t_0, T]$ . Тогда  $k$ -шаговый метод Адамса—Башфорта и  $(k-1)$ -шаговый метод Адамса—Моултона имеют порядок аппроксимации, равный  $k$ .

Следующая теорема дает основание называть методы Адамса, имеющие  $p$ -й порядок аппроксимации, методами  $p$ -го порядка точности.

**Теорема 14.8.** Пусть выполнено условие  $|f'_y| \leq L$ . Тогда явные методы Адамса устойчивы на конечном отрезке. Кроме того, при выполнении условия  $h \leq h_0 = \frac{1}{2|\beta_0|L}$  устойчивыми на конечном отрезке являются и неявные методы Адамса.

**З а м е ч а н и е.** Если выполнено условие  $f'_y \leq 0$ , то неявные методы Адамса устойчивы при любых  $h$ .

**С л е д с т в и е.** Пусть выполнено условие  $|f'_y| \leq L$ . Тогда если  $k$ -шаговый метод Адамса имеет  $p$ -й порядок аппроксимации, а начальные значения  $y_1, y_2, \dots, y_{k-1}$  определяются с  $p$ -м порядком точности, то метод сходится также с  $p$ -м порядком точности.

Следствие верно в силу теоремы 14.4.

Приведем расчетные формулы методов Адамса—Башфорта  $p$ -го порядка точности при  $p = 2, 3, 4$ :

$$y_{n+1} = y_n + \frac{h}{2} (3f_n - f_{n-1}), \quad p = 2;$$

$$y_{n+1} = y_n + \frac{h}{12} (23f_n - 16f_{n-1} + 5f_{n-2}), \quad p = 3;$$

$$y_{n+1} = y_n + \frac{h}{24} (55f_n - 59f_{n-1} + 37f_{n-2} - 9f_{n-3}), \quad p = 4.$$

Приведем также расчетные формулы методов Адамса—Моултона  $p$ -го порядка точности при  $p = 2, 3, 4$ :

$$y_{n+1} = y_n + \frac{h}{2} (f_{n+1} + f_n), p = 2;$$

$$y_{n+1} = y_n + \frac{h}{12} (5f_{n+1} + 8f_n - f_{n-1}), p = 3;$$

$$y_{n+1} = y_n + \frac{h}{24} (9f_{n+1} + 19f_n - 5f_{n-1} + f_{n-2}), p = 4.$$

**2. Методы прогноза и коррекции.** Может показаться, что при наличии явных формул Адамса высокого порядка точности нет необходимости в использовании неявных формул. Однако в вычислительной практике явные методы Адамса используются очень редко. Одна из основных причин этого состоит в том, что в представляющих наибольший интерес для приложений задачах неявные методы обладают лучшими свойствами устойчивости и позволяют вести расчет с существенно большими шагами, нежели явные методы.

Сложность использования неявных методов Адамса заключается в необходимости решать уравнение (14.77) относительно  $y_{n+1}$ . Значение  $y_{n+1}$  можно найти, используя, например, метод простой итерации

$$y_{n+1}^{(s+1)} = \psi(y_{n+1}^{(s)}), s \geq 0, \psi(y) = h\beta_0 f(t_{n+1}, y) + g_n. \quad (14.81)$$

Так как  $\psi'(y) = h\beta_0 f'_y(t_{n+1}, y)$ , то при достаточно малых  $h$  условие сходимости  $|\psi'| \leq g < 1$  выполнено (см. § 4.4) и метод (14.81) сходится.

Часто за начальное приближение  $y_{n+1}^{(0)}$  принимают значение, получаемое по явной формуле Адамса, и выполняют только одну итерацию метода (14.81). В результате приходят к *методу прогноза и коррекции*. Один из широко используемых методов прогноза и коррекции получается при совместном использовании методов Адамса—Башфорта и Адамса—Моултона четвертого порядка точности:

$$\text{Прогноз: } y_{n+1}^{(0)} = y_n + \frac{h}{24} (55f_n - 59f_{n-1} + 37f_{n-2} - 9f_{n-3}),$$

$$f_{n+1}^{(0)} = f(t_{n+1}, y_{n+1}^{(0)}).$$

$$\text{Коррекция: } y_{n+1} = y_n + \frac{h}{24} (9f_{n+1}^{(0)} + 19f_n - 5f_{n-1} + f_{n-2}).$$

Следует подчеркнуть, что результирующий метод оказался явным.

**Пример 14.16.** Применим описанный выше метод Адамса—Башфорта—Моултона четвертого порядка точности для решения задачи Коши (14.45) с шагом  $h = 0.1$ .



В качестве начальных значений  $y_1, y_2, y_3$ , необходимых для начала вычислений, примем значения, полученные методом Рунге—Кутты четвертого порядка точности и приведенные в табл. 14.4. Затем воспользуемся формулами

$$y_{n+1}^{(0)} = y_n + \frac{h}{12} (55t_n y_n - 59t_{n-1} y_{n-1} + 37t_{n-2} y_{n-2} - 9t_{n-3} y_{n-3}),$$

$$y_{n+1} = y_n + \frac{h}{12} (9t_{n+1} y_{n+1}^{(0)} + 19t_n y_n - 5t_{n-1} y_{n-1} + t_{n-2} y_{n-2}).$$

Найденные значения и соответствующие погрешности приведены в табл. 14.5.

Т а б л и ц а 14.5

$t_n$	Прогноз $y_n^{(0)}$	Погрешность прогноза $\varepsilon_n^{(0)}$	Коррекция $y_n$	Погрешность метода $\varepsilon_n$
0.4	1.173420048	$9.1 \cdot 10^{-5}$	1.173518429	$-7.6 \cdot 10^{-6}$
0.5	1.283880725	$1.5 \cdot 10^{-4}$	1.284044297	$-1.9 \cdot 10^{-5}$
0.6	1.433111448	$2.2 \cdot 10^{-4}$	1.433364614	$-3.5 \cdot 10^{-5}$
0.7	1.631994012	$3.3 \cdot 10^{-4}$	1.632374743	$-5.9 \cdot 10^{-5}$
0.8	1.896003688	$4.8 \cdot 10^{-4}$	1.896572568	$-9.2 \cdot 10^{-5}$
0.9	2.247194327	$7.2 \cdot 10^{-4}$	2.248046603	$-1.4 \cdot 10^{-4}$
1.0	2.717200091	$1.1 \cdot 10^{-3}$	2.718486351	$-2.1 \cdot 10^{-4}$

**3. Общие линейные многошаговые методы.** Эти методы, включающие в себя методы Адамса, задаются формулами вида

$$\frac{1}{h} \sum_{j=0}^k \alpha_j y_{n+1-j} = \sum_{j=0}^k \beta_j f_{n+1-j}. \quad (14.82)$$

Предлагается, что  $\alpha_0 \neq 0$ ,  $|\alpha_k| + |\beta_k| \neq 0$ . Они называются линейными, так как значения  $y_i$  и  $f_i$  ( $i = n+1-k, \dots, n, n+1$ ) входят в формулу (14.82) линейно.

**З а м е ч а н и е.** Методы (14.82) принято также называть *конечно-разностными методами*, а дискретную задачу Коши для уравнения (14.82) — *конечно-разностной схемой* (или просто — *разностной схемой*).

**4. Методы с переменным шагом и переменным порядком.** На основе методов Адамса создан ряд весьма сложных, но и эффективных программ. В них предусматривается не только автоматический выбор шага (подобно тому, как это делается для методов Рунге—Кутты), но и

автоматический выбор порядка метода. И шаг метода, и его порядок (в некоторых программах порядок точности может достигать 13) меняются в ходе вычислительного процесса, приспосабливаясь к характеру поведения искомого решения.

Методы Адамса требуют меньшего числа вычислений правой части дифференциального уравнения по сравнению с методами Рунге—Кутты того же порядка точности. Для них существуют эффективные методы апостериорной оценки локальной погрешности. Недостатком методов Адамса является нестандартное начало вычислений. Для определения значений  $y_1, y_2, \dots, y_{k-1}$ , необходимых для работы  $k$ -шагового метода, используются методы Рунге—Кутты либо другие многошаговые методы. В разработанных к настоящему времени стандартных программах эта проблема решена.

#### § 14.8. Устойчивость численных методов решения задачи Коши

Как в теории численных методов решения задачи Коши, так и в практическом плане вопросы об устойчивости методов к малым ошибкам задания начальных данных и правой части уравнения, а также об устойчивости к погрешностям вычислений являются одними из центральных. Рассмотрим некоторые естественные требования устойчивости, которые накладываются на дискретные методы

$$\frac{1}{h} \sum_{j=0}^k \alpha_j y_{n+1-j} = \Phi(t_n, y_{n+k-1}, \dots, y_n, y_{n+1}, h). \quad (14.83)$$

Уделим сначала основное внимание исследованию устойчивости дискретной задачи Коши для уравнения (14.83) к малым погрешностям в начальных данных. Пусть  $y^h$  — решение дискретной задачи, соответствующее начальным значениям  $y_0, y_1, \dots, y_{k-1}$ , а  $y^{*h}$  — решение той же задачи, соответствующее начальным значениям  $y_0^*, y_1^*, \dots, y_{k-1}^*$ . Если отрезок  $[t_0, T]$ , на котором ищется решение, и шаг  $h$  фиксированы, то для всякого приемлемого метода решения задачи Коши его решение непрерывным образом зависит от начальных значений. Более того, если погрешности  $\varepsilon_i = y_i - y_i^* (i = 0, 1, \dots, k-1)$  задания начальных данных достаточно малы, то ошибку значений  $y_n^*$  можно оценить следующим образом:

$$\max_{0 \leq n \leq N} |y_n^* - y_n| \leq K^h(T) \max_{0 \leq i \leq k-1} |\varepsilon_i|. \quad (14.84)$$

Величина  $K^h(T)$ , входящая в правую часть неравенства (14.84), играет роль числа обусловленности метода. Подчеркнем, что в общем случае она зависит как от  $T$ , так и от  $h$ .

1. **Нуль—устойчивость.** Будем стремиться к тому, чтобы при достаточно малых значениях шага  $h$  дискретная задача Коши не только имела близкое к  $y(t)$  решение  $y^h$ , но и обладала другими важными свойствами, аналогичными свойствам исходной задачи. В силу неравенства (14.11) ошибка, внесенная в начальное значение задачи Коши, на отрезке  $[t_0, T]$  возрастает не более, чем в  $K(T)$  раз (где  $K(T)$ , вообще говоря, растет с ростом  $T$ ). Поэтому в общем случае рост величин  $K^h(T)$  с ростом  $T$  также допустим. Однако если коэффициент  $K^h(T)$  может неограниченно возрастать при  $h \rightarrow 0$ , то уменьшение шага  $h$  приведет не к уточнению решения, а, наоборот, к неограниченному росту погрешности. Таким образом, следует потребовать, чтобы для дискретной задачи Коши при всех достаточно малых  $h$  было выполнено неравенство

$$\max_{0 \leq n \leq N} |y_n^* - y_n| \leq \bar{K}(T) \max_{0 \leq i \leq k-1} |\varepsilon_i|, \quad (14.85)$$

где  $\bar{K}(T)$  не зависит от  $h$ .

Методы, для которых неравенство (14.85) выполнено в случае, когда решается задача Коши для однородного уравнения  $y' = 0$ , будем называть *нуль—устойчивыми*.

Чтобы отбросить те из методов (14.83), которые заведомо не обладают свойством нуль—устойчивости, применим метод (14.83) к решению задачи Коши для уравнения  $y' = 0$ . В этом случае  $f \equiv 0$ ,  $\Phi \equiv 0$  и уравнение (14.83) принимает вид

$$\alpha_0 y_{n+1} + \alpha_1 y_n + \dots + \alpha_k y_{n-k+1} = 0. \quad (14.86)$$

Такие уравнения называют *линейными однородными разностными уравнениями  $k$ -го порядка с постоянными коэффициентами*.

Пусть  $y^{*h}$  — решение того же уравнения, соответствующее возмущенным начальным значениям  $y_0^*, y_1^*, \dots, y_{k-1}^*$ . Тогда в силу линейности уравнения погрешность  $\varepsilon_n = y_n - y_n^*$  также является его решением:

$$\alpha_0 \varepsilon_{n+1} + \alpha_1 \varepsilon_n + \dots + \alpha_k \varepsilon_{n-k+1} = 0. \quad (14.87)$$

Будем искать частное решение уравнения (14.87) в виде  $\varepsilon_n = q^n$ . Подставляя  $\varepsilon_{n+1-j} = q^{n+1-j}$  ( $j = 0, 1, \dots, k$ ) в (14.87), и сокращая на об-

щий множитель  $q^{n+1-k}$ , видим, что величина  $q$  должна удовлетворять уравнению

$$\alpha_0 q^k + \alpha_1 q^{k-1} + \dots + \alpha_k = 0, \quad (14.88)$$

которое называют *характеристическим уравнением*, соответствующим методу (14.83). Многочлен  $P(q) = \alpha_0 q^k + \alpha_1 q^{k-1} + \dots + \alpha_k$  называется *характеристическим многочленом*.

Приведем некоторые факты, известные из теории линейных разностных уравнений. Пусть  $q$  — корень уравнения (14.88) (вообще говоря, комплексный). Тогда сеточная функция  $\varepsilon_n = q^n$  является решением разностного уравнения (14.87). Если же  $q$  — кратный корень кратности  $m \geq 2$ , то ему отвечают частные решения  $q^n, nq^n, n^2q^n, \dots, n^{m-1}q^n$ . Опишем теперь структуру общего решения разностного уравнения. Пусть  $q_1, q_2, \dots, q_r$  — корни характеристического уравнения, а  $m_1, m_2, \dots, m_r$  — их кратности ( $m_1 + m_2 + \dots + m_r = k$ ). Тогда всякое решение уравнения (14.87) может быть представлено в виде<sup>1</sup>

$$\varepsilon_n = \sum_{l=0}^{m_1-1} c_1^{(l)} n^l q_1^n + \sum_{l=0}^{m_2-1} c_2^{(l)} n^l q_2^n + \dots + \sum_{l=0}^{m_r-1} c_r^{(l)} n^l q_r^n. \quad (14.89)$$

В частности, если все корни  $q_1, q_2, \dots, q_r$  — простые, то для всякого решения уравнения (14.87) справедливо представление

$$\varepsilon_n = c_1 q_1^n + c_2 q_2^n + \dots + c_r q_r^n.$$

Оказывается, что наличие или отсутствие у метода (14.83) нуль-устойчивости определяется исключительно расположением корней характеристического уравнения.

Будем говорить, что выполнено *корневое условие*, если все корни  $q_1, q_2, \dots, q_r$  характеристического уравнения лежат внутри или на границе единичного круга комплексной плоскости (т.е. удовлетворяют условию  $|q_i| \leq 1, i = 1, 2, \dots, r$ ), причем на границе единичного круга нет кратных корней. Заметим, что в силу равенства (14.30) число  $q = 1$  всегда является корнем характеристического уравнения.

**Теорема 14.9.** *Для того чтобы метод (14.83) обладал нуль-устойчивостью, необходимо и достаточно, чтобы выполнялось корневое условие.*

□ Ограничимся доказательством необходимости выполнения корневого условия. Предположим, что метод обладает свойством нуль-устой-

---

<sup>1</sup> Если среди корней характеристического уравнения имеется корень  $q = 0$  кратности  $s$ , то представление (14.89) верно при  $n \geq s$ .

чивости, а корневое условие не выполнено. Тогда характеристическое уравнение имеет либо корень  $q$  такой, что  $|q| > 1$ , либо корень  $q$  кратности  $m \geq 2$  такой, что  $|q| = 1$ . В первом случае сеточная функция  $\varepsilon^h$  со значениями  $\varepsilon_n = \varepsilon q^n$  есть решение разностного уравнения (14.87), соответствующее заданию начальных значений  $\varepsilon_i = \varepsilon q^i$  ( $i = 0, 1, \dots, k-1$ ). Во втором случае решением, соответствующим заданию начальных значений  $\varepsilon_i = \varepsilon i q^i$  ( $i = 0, 1, \dots, k-1$ ), является функция  $\varepsilon^h$  со значениями  $\varepsilon_n = \varepsilon n q^n$ . И в том, и в другом случаях благодаря выбору  $\varepsilon$  начальные погрешности могут быть сделаны сколь угодно малыми, но в то же время  $|\varepsilon_n| \rightarrow \infty$  при  $n \rightarrow \infty$ .

Учитывая, что  $N = \frac{T - t_0}{h} \rightarrow \infty$  при  $h \rightarrow 0$ , получим  $|y_N^* - y_N| = |\varepsilon_N| \rightarrow \infty$  при  $h \rightarrow 0$ , т.е. неравенство (14.85) не может выполняться для всех  $h$ . Итак, необходимость корневого условия доказана. ■

**Теорема 14.10.** Методы Рунге—Кутты и Адамса обладают свойством нуль-устойчивости.

□ Методам Рунге—Кутты соответствует однородное разностное уравнение  $y_{n+1} - y_n = 0$ , а ему, в свою очередь — характеристическое уравнение  $q - 1 = 0$ . Последнее имеет один простой корень  $q = 1$ , т.е. корневое условие выполнено.

Аналогично,  $k$ -шаговому методу Адамса соответствует разностное уравнение  $y_{n+1} - y_n + 0 \cdot y_{n-1} + \dots + 0 \cdot y_{n-k+1} = 0$ , а ему — характеристическое уравнение  $q^k - q^{k-1} = 0$ . Последнее имеет один простой корень  $q_1 = 1$  и корень  $q_2 = 0$  кратности  $k - 1$ , т.е. корневое условие здесь также выполняется. ■

**Пример 14.17.** Рассмотрим метод

$$\frac{y_{n+1} + y_n - 2y_{n-1}}{3h} = \frac{5f_n + f_{n-1}}{6}, \quad (14.90)$$

имеющий второй порядок аппроксимации<sup>1</sup>. Попытаемся применить его для численного решения задачи Коши  $y'(t) = \cos t$ ,  $y(0) = 0$ . Заметим, что функция  $y(t) = \sin t$  является ее решением.

Возьмем шаг  $h = 0.1$ . Положим  $y_0 = 0$  и в качестве второго начального значения, необходимого для расчета по методу (14.90), примем  $y_1 = 0.1$ . Так как  $y(0.1) = 0.099833\dots$ , то абсолютная погрешность значения  $y_1$  не превышает  $2 \cdot 10^{-4}$ .

---

<sup>1</sup> В наличии второго порядка аппроксимации можно убедиться самостоятельно.

График полученного приближения изображен на рис. 14.13. При  $t > 0.7$  погрешность уже становится заметной. Далее она быстро развивается и при  $t \approx 1.4$  потеря точности становится катастрофической. Попытка увеличить точность решения за счет уменьшения шага вдвое приводит лишь к еще более быстрому нарастанию погрешности. Полная потеря точности происходит здесь уже при  $t \approx 0.9$ . Проверим теперь, выполняется ли для метода (14.90) корневое условие. Характеристическое уравнение имеет вид  $q^2 + q - 2 = 0$ . Корня-

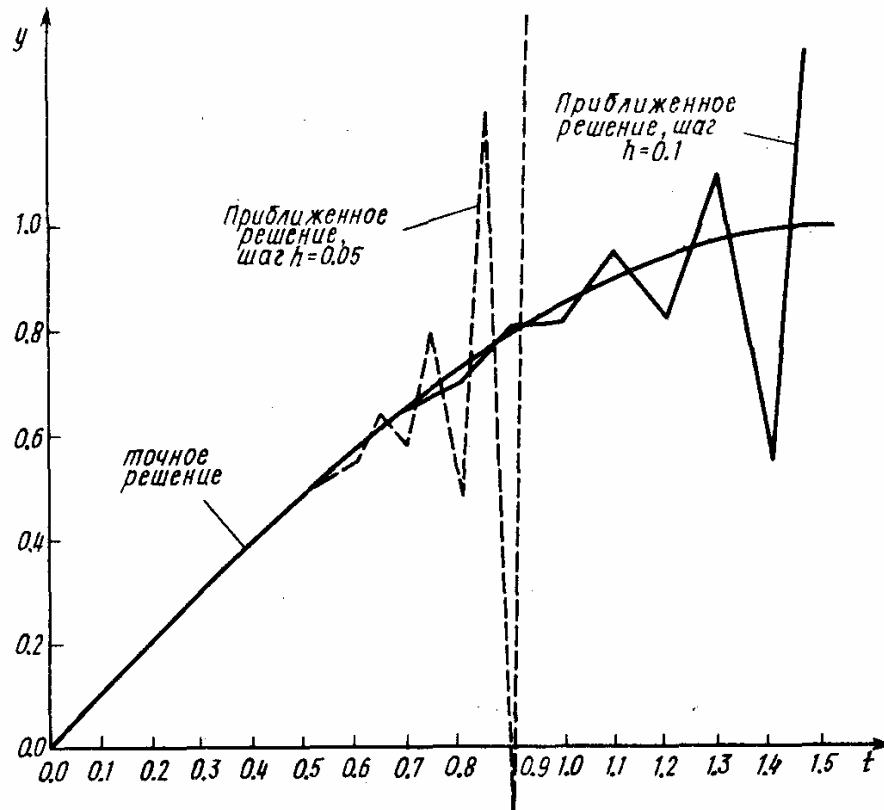


Рис. 14.13

ми уравнения являются числа  $q_1 = 1$ ,  $q_2 = -2$ . Так как  $|q_2| = 2 > 1$ , то корневое условие нарушено. Отсутствие у метода (14.90) нуля-устойчивости и служит причиной наблюдаемого неконтролируемого роста погрешности. Такого рода колебания приближенного решения, вызванные ростом погрешности, иногда называют *четно-нечетной болтанкой*<sup>1</sup>.

Таким образом, для того чтобы численный метод можно было использовать на практике, необходимо, чтобы он был нуля-устойчивым. Игнорирование этого требования даже для методов, обладающих высоким порядком аппроксимации, приводит к катастрофической потере точности.

<sup>1</sup> Конечно это не математический термин, а жаргон.

Оказывается, что для линейных многошаговых методов выполнение корневого условия гарантирует не только нуль-устойчивость метода, но и устойчивость метода на конечном отрезке по начальным значениям и правой части в смысле определения устойчивости (14.28), введенного в § 14.2.

**Теорема 14.11.** Пусть выполнено условие  $|f'_y| \leq L$ . Предположим, что линейный многошаговый метод (14.82) удовлетворяет корневому условию и при  $\beta_0 \neq 0$  (т.е. для неявного метода) выполнено дополнительное условие на шаг:  $h \leq h_0 = \frac{|\alpha_0|}{2|\beta_0|L}$ . Тогда метод (14.82) устойчив на конечном отрезке.

Доказательство этой теоремы можно найти в [71].

**2. Абсолютная устойчивость.** Как уже отмечалось, в § 14.1, необходимость решения задачи Коши на больших временных отрезках  $[t_0, T]$  возникает в самых различных областях науки и техники. Наибольший интерес в этих случаях представляет изучение устойчивых решений. Отметим, что нуль-устойчивость гарантирует устойчивое развитие погрешностей при  $h \rightarrow 0$  только в том случае, когда отрезок интегрирования  $[t_0, T]$  фиксирован. Однако наличие нуль-устойчивости вовсе не исключает того, что сколь угодно малая погрешность в начальных значениях при неограниченном росте  $t_n$  (при  $T \rightarrow \infty$ ) может приводить к сколь угодно большой погрешности решения. Значительную часть таких заведомо непригодных для решения задачи Коши на больших временных отрезках методов можно отбросить, если исследовать результат их применения к решению модельной задачи

$$y' = \lambda y, y(t_0) = y_0. \quad (14.91)$$

Напомним (см. § 14.1), что решение этой задачи устойчиво по Ляпунову, если комплексный параметр  $\lambda$  удовлетворяет условию  $\operatorname{Re} \lambda \leq 0$ , и асимптотически устойчиво, если  $\operatorname{Re} \lambda < 0$ .

Большинство используемых дискретных методов (в том числе и методы Рунге—Кутты и Адамса) в применении к задаче (14.91) становятся линейными и приобретают вид

$$\frac{1}{h} \sum_{j=0}^k \alpha_j y_{n+1-j} = \lambda \sum_{j=0}^k \beta_j(h\lambda) y_{n+1-j}. \quad (14.92)$$

Здесь  $\beta_j(h\lambda)$  — некоторые зависящие от величины  $z = \lambda h$  функции.

В силу линейности уравнения (14.92) ошибка  $\varepsilon_n = y_n - y_n^*$ , возни-

кающая из-за погрешностей в начальных значениях, удовлетворяет тому же уравнению:

$$\frac{1}{h} \sum_{j=0}^k \alpha_j \varepsilon_{n+1-j} = \lambda \sum_{j=0}^k \beta_j(h\lambda) \varepsilon_{n+1-j}.$$

Перепишем это уравнение в виде

$$\sum_{j=0}^k \gamma_j(z) \varepsilon_{n+1-j} = 0, \quad (14.93)$$

где  $\gamma_j(z) = \alpha_j - z\beta_j(z)$ ,  $z = h\lambda$ . Заметим, что (14.93) — это линейное однородное разностное уравнение. Поэтому для того чтобы при фиксированном  $z$  погрешность  $\varepsilon_n$  оставалась ограниченной при  $n \rightarrow \infty$ , необходимо и достаточно выполнение корневого условия для отвечающего уравнению (14.93) полинома.

Назовем метод (14.83) *абсолютно устойчивым* для данного  $z = h\lambda$ , если при этом  $z$  все корни полинома устойчивости

$$P(q, z) = \sum_{j=0}^k \gamma_j(z) q^{k-j} \quad (14.94)$$

лежат в комплексной плоскости внутри единичного круга и на границе этого круга нет кратных корней. Множество  $D$  точек комплексной плоскости, состоящее из тех  $z$ , для которых метод абсолютно устойчив, называют *областью абсолютной устойчивости* метода.

**Пример 14.18.** Найдем область абсолютной устойчивости метода Эйлера.

Применительно к модельному уравнению  $y' = \lambda y$  расчетная формула метода Эйлера принимает вид  $y_{n+1} = y_n + h\lambda y_n$ . Запишем соответствующее разностное уравнение для погрешности

$$\varepsilon_{n+1} - (1 + h\lambda) \varepsilon_n = 0 \quad (14.95)$$

и заметим, что полином устойчивости  $P(q, z) = q - (1 + z)$  имеет один простой корень  $q = 1 + z$ . Область абсолютной устойчивости состоит здесь из тех  $z = h\lambda$ , для которых  $|1 + z| \leq 1$ , и представляет собой в комплексной плоскости круг единичного радиуса с центром в точке  $z_0 = -1$  (рис. 14.14, а).

Тот же результат нетрудно установить, не используя полином устойчивости и корневое условие. Действительно, из уравнения (14.95) следует, что  $\varepsilon_n = (1 + h\lambda)^n \varepsilon_0$ . Поэтому  $|\varepsilon_n| = |1 + h\lambda|^n |\varepsilon_0|$  и  $\varepsilon_n \rightarrow \infty$  при  $n \rightarrow \infty$ , если  $|1 + h\lambda| > 1$ . В этом случае метод не является устойчивым. Наоборот, если  $|1 + h\lambda| \leq 1$ , то  $|\varepsilon_n| \leq |\varepsilon_0|$  и метод устойчив.



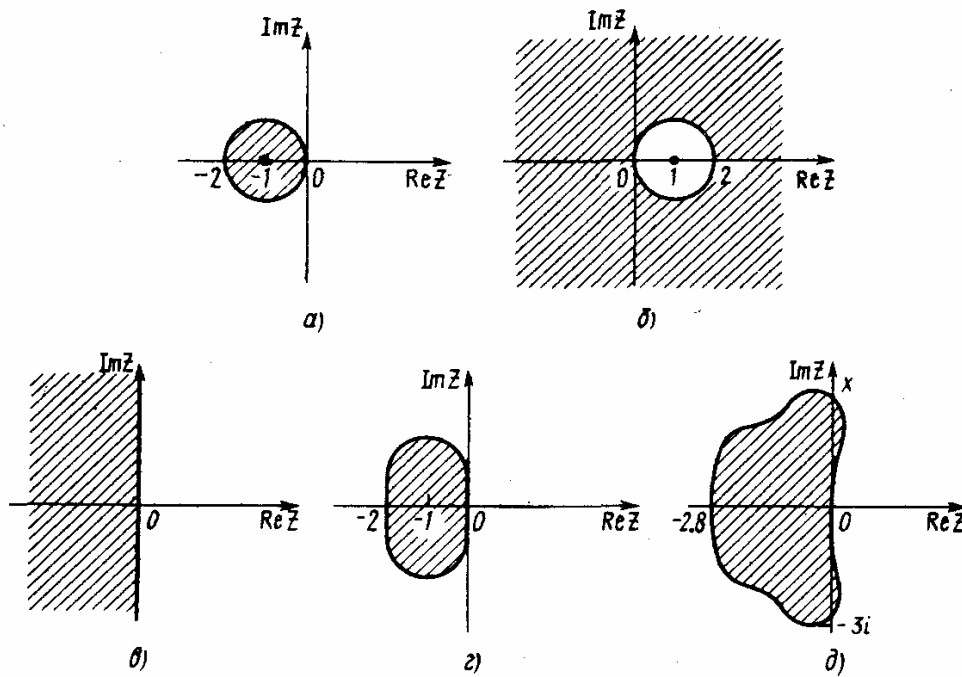


Рис. 14.14

**Пример 14.19.** Найдем области абсолютной устойчивости для неявного метода Эйлера (14.24), правила трапеций (14.25), метода Эйлера—Коши (14.61) и усовершенствованного метода Эйлера (14.62).

Применительно к модельному уравнению неявный метод Эйлера принимает вид  $y_{n+1} = y_n + h\lambda y_{n+1}$ . Соответствующий полином устойчивости  $(1 - z)q - 1$  имеет единственный корень  $q = (1 - z)^{-1}$ . Условие  $|q| \leq 1$  эквивалентно здесь условию  $|1 - z| \geq 1$ . Таким образом, область устойчивости представляет собой внешнюю часть единичного круга с центром в точке  $z_0 = 1$  (рис. 14.14, б).

Для правила трапеций  $y_{n+1} = y_n + \frac{h\lambda}{2} (y_n + y_{n+1})$  полином устойчивости  $P(q, z) = (1 - \frac{z}{2})q - (1 + \frac{z}{2})$  имеет корень  $q = (2 + z)/(2 - z)$ . Условие  $|q| \leq 1$  эквивалентно здесь неравенству  $\operatorname{Re} z \leq 0$ . Поэтому область устойчивости представляет собой левую полуплоскость (рис. 14.14, в).

Применительно к уравнению  $y' = \lambda y$  расчетные формулы методов (14.61) и (14.62) совпадают:  $y_{n+1} = y_n + \frac{h\lambda}{2} (2 + h\lambda)y_n$ . Корнем полинома устойчивости  $q - (1 + z + \frac{z^2}{2})$  является  $q = 1 + z + \frac{z^2}{2}$ . Область абсолютной устойчивости изображена на рис. 14.14, г. Для сравнения на рис. 14.14, д схематично изображена область абсолютной устойчивости метода Рунге—Кутты четвертого порядка точности.

Предположим, что параметр  $\lambda$ , входящий в модельное уравнение (14.91), отрицателен. Тогда условие абсолютной устойчивости метода Эйлера  $|1 + h\lambda| \leq 1$  оказывается эквивалентным неравенству

$$h \leq h_0 = \frac{2}{|\lambda|}. \quad (14.96)$$

Такое же ограничение на шаг возникает при использовании метода Эйлера—Коши и усовершенствованного метода Эйлера. В то же время метод Рунге—Кутты четвертого порядка точности оказывается абсолютно устойчивым при выполнении чуть менее ограничительного условия

$$h \leq h_0 \approx \frac{2.8}{|\lambda|}. \quad (14.97)$$

Отметим, что при  $\lambda < 0$  неявный метод Эйлера и правило трапеций оказываются абсолютно устойчивыми при любых  $h$ .

**3. А-устойчивость.** Для того чтобы исключить ограничение на шаг  $h$  при решении устойчивой по Ляпунову модельной задачи (14.91), необходимо потребовать, чтобы область абсолютной устойчивости метода включала в себя полуплоскость  $\operatorname{Re} z < 0$ . Численный метод, обладающий таким свойством, называют *А-устойчивым*.

Примерами А-устойчивых методов служат неявный метод Эйлера и правило трапеций. В то же время метод Эйлера и метод Рунге—Кутты четвертого порядка точности не являются А-устойчивыми.

## § 14.9. Неявный метод Эйлера

Как следует из результатов предыдущего параграфа, простейшим представителем семейства А-устойчивых методов является неявный метод Эйлера

$$y_{n+1} = y_n + hf(t_{n+1}, y_{n+1}). \quad (14.98)$$

Как нетрудно понять, геометрическая интерпретация одного шага метода (14.98) заключается в том, что решение на отрезке  $[t_n, t_{n+1}]$  аппроксимируется касательной  $y = y_{n+1} + y'(t_{n+1})(t - t_{n+1})$ , проведенной в точке  $(t_{n+1}, y_{n+1})$  к интегральной кривой, проходящей через эту точку (рис. 14.15).

Достоинства неявного метода Эйлера проявляются при решении

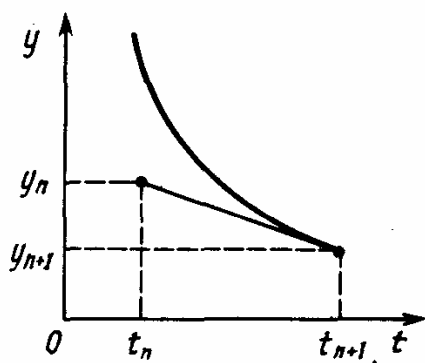


Рис. 14.15

дифференциальных уравнений, имеющих устойчивые по Ляпунову решения. Как уже отмечалось в § 14.2, достаточным условием такой устойчивости является выполнение одностороннего условия Липшица  $f'_y \leq 0$ .

Пусть  $y^h$  — решение дискретной задачи Коши для уравнения (14.98) соответствующее начальному условию  $y^h(t_0) = y_0$ , а  $y^{*h}$  — решение возмущенной

задачи

$$\begin{aligned} y_{n+1}^{*h} &= y_n^{*h} + h(f(t_{n+1}, y_{n+1}^{*h}) + \psi_n), \\ y^{*h}(t_0) &= y_0^*. \end{aligned} \quad (14.99)$$

Аналогично теореме 14.5 можно доказать следующий результат.

**Теорема 14.12.** Пусть функция  $f$  удовлетворяет условию  $f'_y \leq 0$ . Тогда справедливо неравенство

$$\max_{0 \leq n \leq N} |y_n - y_n^*| \leq |y_0 - y_0^*| + h \sum_{k=1}^{N-1} |\psi_k|, \quad (14.100)$$

означающее, что неявный метод Эйлера устойчив на конечном отрезке.

Заметим, что неравенство (14.100) является дискретным аналогом оценки (14.16), справедливой для погрешности решения задачи Коши (при этом  $K(T) = 1$ ). Следует отметить, что оно верно для метода (14.98) при любых  $h$ , в то время как для явного метода Эйлера это неравенство имеет место только если  $-L \leq f'_y \leq 0$  и  $h \leq h_0 = 2/L$ .

Для неявного метода Эйлера справедлив и дискретный аналог оценки (14.17).

**Теорема 14.13.** Пусть функция  $f$  удовлетворяет условию  $f'_y \leq \sigma < 0$ . Тогда справедливо неравенство

$$|y_n - y_n^*| \leq e^{\sigma h(t_n - t_0)} |y_0 - y_0^*| + \frac{1}{|\sigma h|} \max_{0 \leq k < n} |\psi_k|, \quad (14.101)$$

где  $\sigma_h = \frac{\sigma}{1 - \sigma_h} \rightarrow \sigma$  при  $h \rightarrow 0$ .

Из того, что неявный метод Эйлера устойчив и имеет первый порядок аппроксимации, вытекает (в силу теоремы 14.4) его сходимость с первым порядком. Приведем соответствующий результат.

**Теорема 14.14.** Пусть функция  $f$  удовлетворяет условию  $f'_y \leq 0$ . Тогда для неявного метода Эйлера справедлива следующая оценка погрешности:

$$\max_{0 \leq n \leq N} |y_n - y_n^*| \leq \int_{t_0}^T |y''(t)| dt \cdot h. \quad (14.102)$$

Если же функция  $f$  удовлетворяет условию  $f'_y \leq \sigma < 0$ , то верна оценка

$$\max_{0 \leq n \leq N} |y_n - y_n^*| \leq \frac{M_2}{2} \left[ \frac{1}{|\sigma|} + h \right] h, \quad (14.103)$$

$$\text{ide } M_2 = \max_{[t_0, T]} |y''(t)|.$$

Последняя оценка замечательна тем, что ее правая часть не растет с ростом  $T$ , если вторая производная решения ограничена.

### § 14.10. Решение задачи Коши для систем обыкновенных дифференциальных уравнений и дифференциальных уравнений $m$ -го порядка

**1. Задача Коши для систем дифференциальных уравнений первого порядка.** Как правило, возникающие в приложениях проблемы приводят к необходимости решать задачу Коши не для одного дифференциального уравнения, а для систем дифференциальных уравнений вида

$$\begin{aligned} y_1'(t) &= f_1(t, y_1(t), y_2(t), \dots, y_m(t)), \\ y_2'(t) &= f_2(t, y_1(t), y_2(t), \dots, y_m(t)) \\ &\vdots \\ y_m'(t) &= f_m(t, y_1(t), y_2(t), \dots, y_m(t)). \end{aligned} \quad (14.104)$$

Здесь  $y_1(t), y_2(t), \dots, y_m(t)$  — искомые функции, значения которых подлежат определению при  $t \in [t_0, T]$ . В момент времени  $t = t_0$  задаются *начальные условия*

$$y_1(t_0) = y_{10}, y_2(t_0) = y_{20}, \dots, y_m(t_0) = y_{m0}, \quad (14.105)$$

определяющие начальное состояние физической системы, развитие которой описывается уравнениями (14.104).

Введем вектор-функции  $\mathbf{y}(t) = (y_1(t), y_2(t), \dots, y_m(t))^T$ ,  $\mathbf{f}(t, \mathbf{y}) = (f_1(t, \mathbf{y}), f_2(t, \mathbf{y}), \dots, f_m(t, \mathbf{y}))^T$  и вектор  $\mathbf{y}_0 = (y_{10}, y_{20}, \dots, y_{m0})^T$ . Тогда задачу Коши (14.104), (14.105) можно записать в компактной форме:

$$\mathbf{y}'(t) = \mathbf{f}(t, \mathbf{y}(t)), \quad (14.106)$$

$$\mathbf{y}(t_0) = \mathbf{y}_0. \quad (14.107)$$

Для того чтобы охватить ряд важных для технических приложений задач (электротехника, радиотехника и др.), будем считать, что функции  $y_i$  и  $f_i$  ( $i = 1, 2, \dots, m$ ) могут принимать комплексные значения.

**2. Разрешимость задачи Коши.** Пусть  $\Pi_T$  — множество таких точек  $(t, \mathbf{y})$ , для которых  $t \in [t_0, T]$ , а  $y_1, y_2, \dots, y_m$  — произвольные комплексные числа. Это множество будем называть *слоем*. Будем, как и ранее, использовать обозначения  $(\mathbf{y}, \mathbf{z}) = \sum_{i=1}^m y_i \bar{z}_i$  и  $\|\mathbf{y}\| = \left( \sum_{i=1}^m |y_i|^2 \right)^{1/2}$  для скалярного произведения и нормы  $m$ -мерных комплексных векторов.

Сформулируем аналог теоремы 14.1 о разрешимости задачи Коши.

**Теорема 14.15.** Пусть вектор-функция  $\mathbf{f}(t, \mathbf{y})$  определена и непрерывна в слое  $\Pi_T$ . Предположим также, что она удовлетворяет условию Липшица

$$\|\mathbf{f}(t, \mathbf{y}_1) - \mathbf{f}(t, \mathbf{y}_2)\| \leq L \|\mathbf{y}_1 - \mathbf{y}_2\|, \quad (14.108)$$

для всех  $t_0 \leq t \leq T$  и произвольных  $\mathbf{y}_1, \mathbf{y}_2$ , где  $L > 0$  — некоторая постоянная (постоянная Липшица).

Тогда для каждого начального значения  $\mathbf{y}_0$  существует единственное решение  $\mathbf{y}(t)$  задачи Коши (14.106), (14.107), определенное на отрезке  $[t_0, T]$ .

**З а м е ч а н и е 1.** Можно показать, что если функции  $f_1, f_2, \dots, f_m$  непрерывно дифференцируемы по  $y_1, y_2, \dots, y_m$ , то условие Липшица (14.108) выполняется с постоянной  $L$  тогда и только тогда, когда матрица Якоби

$$f'_y(t, y) = \begin{bmatrix} f'_{1y_1}(t, y) & f'_{1y_2}(t, y) & \dots & f'_{1y_m}(t, y) \\ f'_{2y_1}(t, y) & f'_{2y_2}(t, y) & \dots & f'_{2y_m}(t, y) \\ \dots & \dots & \dots & \dots \\ f'_{my_1}(t, y) & f'_{my_2}(t, y) & \dots & f'_{my_m}(t, y) \end{bmatrix}$$

удовлетворяет неравенству  $\|f'_y(t, y)\| \leq L$ .

**З а м е ч а н и е 2.** Теорема 14.16 остается справедливой, если в ее формулировке условие Липшица (14.108) заменить менее ограничительным *односторонним условием Липшица*

$$\operatorname{Re}(f(t, y_1) - f(t, y_2), y_1 - y_2) \leq \sigma \|y_1 - y_2\|^2. \quad (14.109)$$

Назовем систему дифференциальных уравнений *диссипативной*, если вектор-функция  $f$  удовлетворяет неравенству

$$\operatorname{Re}(f(t, y_1) - f(t, y_2), y_1 - y_2) \leq 0$$

(т.е. если  $f$  удовлетворяет одностороннему условию Липшица с постоянной  $\sigma = 0$ ).

**3. Устойчивость решения задачи Коши.** Приведем аналог теоремы 14.3.

**Т е о р е м а 14.16.** Пусть выполнены условия теоремы 14.15. Далее, пусть  $y(t)$  — решение задачи (14.106), (14.107), а  $y^*(t)$  — решение задачи

$$(y^*)'(t) = f(t, y^*(t)) + \psi(t), \quad (14.110)$$

$$y^*(t_0) = y_0^*. \quad (14.111)$$

Тогда справедлива оценка

$$\max_{t_0 \leq t \leq T} \|y(t) - y^*(t)\| \leq K(T)(\|y_0 - y_0^*\| + \int_{t_0}^T \|\psi(t)\| dt), \quad (14.112)$$

выражающая устойчивость на конечном отрезке  $[t_0, T]$  решения задачи Коши по начальным значениям и правой части. Здесь  $K(T) = e^{L(T-t_0)}$ .

Если в теореме 14.15 условие Липшица (14.108) заменить односто-

ронным условием (14.109), то оценка (14.112) будет выполнена с постоянной  $K(T) = e^{\sigma(T-t_0)}$  при  $\sigma > 0$  и с постоянной  $K(T) = 1$  при  $\sigma \leq 0$ .

**С л е д с т в и е.** Если система (14.106) диссипативна, то справедлива оценка

$$\max_{t_0 \leq t \leq T} \|y(t) - y^*(t)\| \leq \|y_0 - y_0^*\| + \int_{t_0}^T \|\psi(t)\| dt. \quad (14.113)$$

**З а м е ч а н и е.** Можно показать, что если условие (14.109) выполнено с постоянной  $\sigma < 0$ , то для всех  $t \in [t_0, T]$  справедлива оценка

$$\|y(t) - y^*(t)\| \leq e^{\sigma(T-t_0)} \|y_0 - y_0^*\| + \frac{1}{|\sigma|} \max_{t_0 \leq t' \leq t} \|\psi(t')\|. \quad (14.114)$$

По аналогии со случаем одного дифференциального уравнения (см. § 14.1) рассмотрим вопрос об устойчивости решения задачи Коши к возмущениям начальных данных при  $T \rightarrow \infty$ . Будем считать, что на каждом отрезке  $[t_0, T]$  ( $t_0 < T$  — произвольно) неравенство (14.109) выполнено с некоторой постоянной  $\sigma = \sigma(T)$ . Тогда решение  $y(t)$  определено для всех  $t_0 \leq t < \infty$ . Пусть  $y^*(t)$  — решение задачи (14.110), (14.111), отвечающее произвольному начальному значению  $y_0^*$  и  $\psi(t) \equiv 0$ . Будем называть решение задачи Коши (14.106), (14.107) *устойчивым по Ляпунову*, если справедлива оценка  $\max_{t_0 \leq t' \leq T} \|y(t) - y^*(t)\| \leq K \|y_0 - y_0^*\|$ , где постоянная  $K$  не зависит от  $N$ . Если дополнительно известно, что  $\|y(t) - y^*(t)\| \rightarrow 0$  при  $t \rightarrow \infty$ , то решение называется *асимптотически устойчивым*.

**З а м е ч а н и е 1.** При  $\psi(t) \equiv 0$  из неравенства (14.113) получаем оценку  $\max_{t_0 \leq t \leq T} \|y(t) - y^*(t)\| \leq \|y_0 - y_0^*\|$ . Поэтому всякое решение

диссипативной системы является устойчивым по Ляпунову.

**З а м е ч а н и е 2.** Предположим, что одностороннее условие Липшица (14.109) для всех  $t_0 \leq t < \infty$  выполняется с одной и той же постоянной  $\sigma < 0$ . Тогда при  $\psi(t) \equiv 0$  из неравенства (14.114) получаем оценку

$$\|y(t) - y^*(t)\| \leq e^{\sigma(T-t_0)} \|y_0 - y_0^*\|,$$

откуда следует, что  $\|y(t) - y^*(t)\| \rightarrow 0$  при  $t \rightarrow \infty$ , т.е. решение  $y(t)$  асимптотически устойчиво.

**4. Система линейных уравнений с постоянными коэффициентами.**  
Рассмотрим систему

$$y'(t) = Ay(t), \quad (14.115)$$

являющуюся простейшим примером системы дифференциальных уравнений первого порядка; здесь  $A$  — квадратная матрица порядка  $m$ . В теории численных методов решения систем дифференциальных уравнений система (14.115) играет роль, аналогичную той, которую при исследовании методов численного интегрирования одного уравнения  $y' = f(t, y)$  выполняет модельное уравнение  $y'(t) = \lambda y(t)$  (см. § 14.1).

Напомним структуру решения системы линейных уравнений с постоянными коэффициентами в наиболее простом и важном случае, когда матрица  $A$  имеет простую структуру. В этом случае существует набор  $e_1, e_2, \dots, e_m$  собственных векторов матрицы  $A$ , соответствующих собственным значениям  $\lambda_1, \lambda_2, \dots, \lambda_m$ , который образует базис в пространстве  $m$ -мерных векторов. Матрица  $P$ , столбцами которой служат векторы  $e_1, e_2, \dots, e_m$ , не вырождена и такова, что

$$P^{-1}AP = \Lambda = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_m \end{bmatrix}. \quad (14.116)$$

Обозначим через  $z_1(t), z_2(t), \dots, z_m(t)$  координаты вектора  $y(t)$  в базисе  $e_1, \dots, e_m$ . Так как

$$y(t) = z_1(t)e_1 + z_2(t)e_2 + \dots + z_m(t)e_m, \quad (14.117)$$

то вектор  $y(t)$  связан с вектором  $z(t) = (z_1(t), z_2(t), \dots, z_m(t))^T$  равенством  $y(t) = Pz(t)$ . Умножив обе части системы (14.115) слева на  $P^{-1}$ , получим для вектор-функции  $z(t)$  систему уравнений

$$z'(t) = \Lambda z(t).$$



В силу диагональной структуры матрицы  $\Lambda$  эта система распадается на  $m$  независимых дифференциальных уравнений

$$z_i'(t) = \lambda_i z_i(t), \quad i = 1, 2, \dots, m. \quad (14.118)$$

Заметим, что уравнение (14.118) для  $i$ -й компоненты вектора есть модельное уравнение с параметром  $\lambda = \lambda_i$ .

Таким образом, в рассматриваемом случае интегрирование системы линейных дифференциальных уравнений эквивалентно интегрированию  $m$  модельных уравнений (14.118). Решая каждое из них, получим

$z_i(t) = c_i e^{\lambda_i(t-t_0)}$ ,  $c_i = z_i(t_0)$  и в силу равенства (14.117) находим

$$\mathbf{y}(t) = \sum_{i=1}^m c_i e^{\lambda_i(t-t_0)} \mathbf{e}_i.$$

Здесь  $\mathbf{c} = (c_1, c_2, \dots, c_m)^T = P^{-1} \mathbf{y}_0$ .

Пусть  $\boldsymbol{\varepsilon}(t) = \mathbf{y}(t) - \mathbf{y}^*(t)$  — погрешность решения, вызванная погрешностью начальных значений  $\boldsymbol{\varepsilon}_0 = \mathbf{y}_0 - \mathbf{y}_0^*$ . В силу линейности системы (14.117) погрешность является решением той же системы:  $\boldsymbol{\varepsilon}'(t) = A \boldsymbol{\varepsilon}(t)$ . Следовательно,

$$\boldsymbol{\varepsilon}(t) = \sum_{i=1}^m \alpha_i e^{\lambda_i(t-t_0)} \mathbf{e}_i, \quad (14.119)$$

где  $\boldsymbol{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_m)^T = P^{-1} \boldsymbol{\varepsilon}_0$ .

Формула (14.119) позволяет сделать ряд важных выводов. В частности, из нее следует, что решение системы (14.115) с постоянной матрицей  $A$  простой структуры устойчиво по Ляпунову тогда и только тогда, когда  $\operatorname{Re} \lambda_i \leq 0$  для всех  $i = 1, 2, \dots, m$  и асимптотически устойчиво тогда и только тогда, когда  $\operatorname{Re} \lambda_i < 0$  для всех  $i = 1, 2, \dots, m$ . Отметим также, что в отличие от случая одного дифференциального уравнения для систем характерно наличие  $m$  временных постоянных  $\tau_i = \frac{1}{|\operatorname{Re} \lambda_i|}$ ,  $i = 1, 2, \dots, m$ . Наличие в решении задачи физических компонент с существенно различными временными постоянными может привести к серьезным затруднениям при численном решении соответствующих задач. Более подробно этот вопрос рассматривается в следующем параграфе.

Пусть теперь  $\mathbf{y}^*(t)$  — решение нелинейной системы

$$(\mathbf{y}^*)'(t) = \mathbf{f}(t, \mathbf{y}^*(t)), \quad (14.120)$$

отвечающее возмущенному начальному условию  $\mathbf{y}^*(t_0) = \mathbf{y}_0^*$ . Вычитая из уравнения (14.120) уравнение  $\mathbf{y}'(t) = \mathbf{f}(t, \mathbf{y}(t))$  и используя приближенное равенство



$$k_n^{(1)} = f(t_n, y_n), \quad k_n^{(2)} = f\left(t_n + \frac{h}{2}, y_n + \frac{h}{2} k_n^{(1)}\right),$$

$$k_n^{(3)} = f\left(t_n + \frac{h}{2}, y_n + \frac{h}{2} k_n^{(2)}\right), \quad k_n^{(4)} = f(t_n + h, y_n + h k_n^{(3)}).$$

Теория численных методов решения задачи Коши для систем дифференциальных уравнений имеет много общего с соответствующей теорией решения задачи Коши для одного дифференциального уравнения. В частности, справедливы аналогии всех изложенных выше результатов, касающихся устойчивости и сходимости дискретных методов на конечном отрезке. Однако имеют место и существенно новые явления. Один из таких эффектов — жесткость — будет рассмотрен в следующем параграфе. Прежде чем переходить к его изложению, выясним, какие изменения появляются в случае применения дискретных методов к решению задачи Коши для системы уравнений с постоянными коэффициентами (14.115).

Рассмотрим линейный многошаговый метод

$$\frac{1}{h} \sum_{j=0}^k \alpha_j y_{n+1-j} = \sum_{j=0}^k \beta_j A y_{n+1-j}. \quad (14.121)$$

Предположим для простоты, что матрица  $A$  имеет простую структуру. Положим  $z_n = P^{-1} y_n$ , где  $P$  — матрица, удовлетворяющая равенству (14.116). Умножив обе части уравнения (14.121) на матрицу  $P^{-1}$  слева и учитывая, что

$$y_{n+1-j} = P z_{n+1-j}, \quad P^{-1} A y_{n+1-j} = P^{-1} A P z_{n+1-j} = \Lambda z_{n+1-j},$$

получим соотношение

$$\frac{1}{h} \sum_{j=0}^k \alpha_j z_{n+1-j} = \sum_{j=0}^k \beta_j \Lambda z_{n+1-j}.$$

Так как матрица  $\Lambda$  — диагональная, то оно эквивалентно следующей системе уравнений для компонент вектора  $z_n = (z_{1n}, z_{2n}, \dots, z_{mn})^T$ :

$$\frac{1}{h} \sum_{j=0}^k \alpha_j z_{i,n+1-j} = \sum_{j=0}^k \beta_j \lambda_i z_{i,n+1-j}, \quad i = 1, 2, \dots, m. \quad (14.122)$$

Заметим, что (14.122) есть не что иное, как результат применения линейного многошагового метода к решению уравнений (14.18).

Таким образом, если решения системы (14.115) устойчивы по Ляпунову, то для того чтобы погрешности  $\varepsilon_n$  оставались ограниченными при  $n \rightarrow \infty$ , необходимо потребовать, чтобы для всех  $i = 1, \dots, m$  величина  $h\lambda_i$  принадлежала области  $D$  абсолютной устойчивости применяемого метода. Можно показать, что такой же вывод справедлив и для методов Рунге—Кутты. Требование, чтобы  $h\lambda_i \in D$  при всех  $i = 1, 2, \dots$ ,

$m$ , для методов, не обладающих свойством  $A$ -устойчивости, может приводить к существенным ограничениям на величину шага  $h$ .

Предположим, например, что все собственные значения матрицы  $A$  отрицательны. Тогда условие (14.96) абсолютной устойчивости метода Эйлера приводит к следующему ограничению на длину шага интегрирования:

$$h \leq h_0 = \frac{2}{\max_{1 \leq i \leq m} |\lambda_i|}. \quad (14.123)$$

Такое же ограничение на шаг возникает при использовании метода Эйлера—Коши и усовершенствованного метода Эйлера. Метод Рунге—Кутты четвертого порядка точности, как следует из неравенства (14.97), оказывается абсолютно устойчивым при таком ограничении на длину шага:

$$h \leq h_0 \approx \frac{2.8}{\max_{1 \leq i \leq m} |\lambda_i|}.$$

Следовательно, для явных методов шаг интегрирования должен не превышать значения  $h_0$ , пропорционального наименьшей из временных постоянных системы.

**6. Сведение задачи Коши для уравнения  $m$ -го порядка к задаче Коши для системы уравнений первого порядка.** Задача Коши для дифференциального уравнения  $m$ -го порядка состоит в нахождении функции  $y(t)$ , удовлетворяющей при  $t \geq t_0$  дифференциальному уравнению

$$y^{(m)}(t) = f(t, y(t), y'(t), \dots, y^{(m-1)}(t)), \quad (14.124)$$

а при  $t = t_0$  - начальным условиям

$$y(t_0) = y_{10}, y'(t_0) = y_{20}, \dots, y^{(m-1)}(t_0) = y_{m0}. \quad (14.125)$$

Рассмотрим функции  $y_1(t) = y(t)$ ,  $y_2(t) = y'(t)$ , ...,  $y_m(t) = y^{(m-1)}(t)$ . Заметим, что  $y_k(t) = (y_{k-1})'(t)$ . Поэтому введенные функции удовлетворяют системе дифференциальных уравнений первого порядка

$$\begin{aligned} y_1'(t) &= y_2(t), \\ y_2'(t) &= y_3(t), \\ &\dots \dots \dots \\ y_{m-1}'(t) &= y_m(t), \\ y_m'(t) &= f(t, y_1(t), y_2(t), \dots, y_m(t)). \end{aligned} \quad (14.126)$$

Начальные условия (14.125) в новых обозначениях принимают вид

$$y_1(t_0) = y_{10}, y_2(t_0) = y_{20}, \dots, y_m(t_0) = y_{m0}. \quad (14.127)$$

**Пример 14.21.** Задача Коши для дифференциального уравнения второго порядка  $y'' = -25y + \sin t$ ,  $y(0) = 0$ ,  $y'(0) = 1$  введением новых искомых функций  $y_1(t) = y(t)$ ,  $y_2(t) = y'(t)$  сводится к эквивалентной задаче Коши для системы дифференциальных уравнений первого порядка  $y_1' = y_2$ ,  $y_2' = -25y_1 + \sin t$ ,  $y_1(0) = 0$ ,  $y_2(0) = 1$ .

Для решения задачи Коши (14.124), (14.125), приведенной к виду (14.126), (14.127), можно воспользоваться известными методами или даже готовыми программами. Часто именно так и поступают. Следует все же иметь в виду, что вычисления можно организовать и так, что сведение уравнения (14.124) к системе (14.126) не потребуется. Например, для решения дифференциального уравнения второго порядка  $y'' = f(t, y)$  используется ряд специальных методов [88]. Одним из наиболее популярных среди них является *метод Рунге* четвертого порядка точности:

$$\frac{y_{n+1} - 2y_n + y_{n-1}}{h^2} = \frac{1}{12} (f(t_{n-1}, y_{n-1}) + 10f(t_n, y_n) + f(t_{n+1}, y_{n+1})).$$

## § 14.11. Жесткие задачи

**1. Понятие о жестких задачах.** В последние годы при решении задачи Коши явными методами Рунге—Кутты и Адамса значительное число исследователей сталкивается с весьма неожиданным и неприятным явлением. Несмотря на медленное изменение искомых функций расчет приходится вести, казалось бы, с неоправданно мелким шагом  $h$ . Все попытки увеличить шаг и тем самым уменьшить время решения задачи приводят лишь к катастрофически большому росту погрешности. Обладающие таким свойством задачи получили название *жестких*. Сразу же подчеркнем, что жесткость является свойством задачи Коши (а не используемых численных методов).

Жесткие задачи встречаются в самых различных областях науки и техники. Традиционными источниками появления таких задач являются химическая кинетика, теория ядерных реакторов, теория автоматического управления, электротехника, электроника и т.д. Жесткие задачи возникают также при аппроксимации начально-краевых задач

для уравнений в частных производных с помощью полудискретных методов (методов прямых).

Трудности, возникающие при численном решении жестких задач, продемонстрируем на таком примере.

**Пример 14.22.** Вычислим значения приближенного решения задачи Коши

$$y'(t) = -25y(t) + \cos t + 25\sin t, \quad y(0) = 1, \quad (14.128)$$

используя метод Эйлера. Решением этой задачи является функция  $y(t) = \sin t + e^{-25t}$ . Как нетрудно видеть (рис. 14.16), на начальном переходном участке  $0 \leq t \leq 0.2$  решение быстро меняется. Однако уже через небольшой интервал времени переходная часть решения  $e^{-25t}$  практически исчезает и решение становится медленно меняющимся.

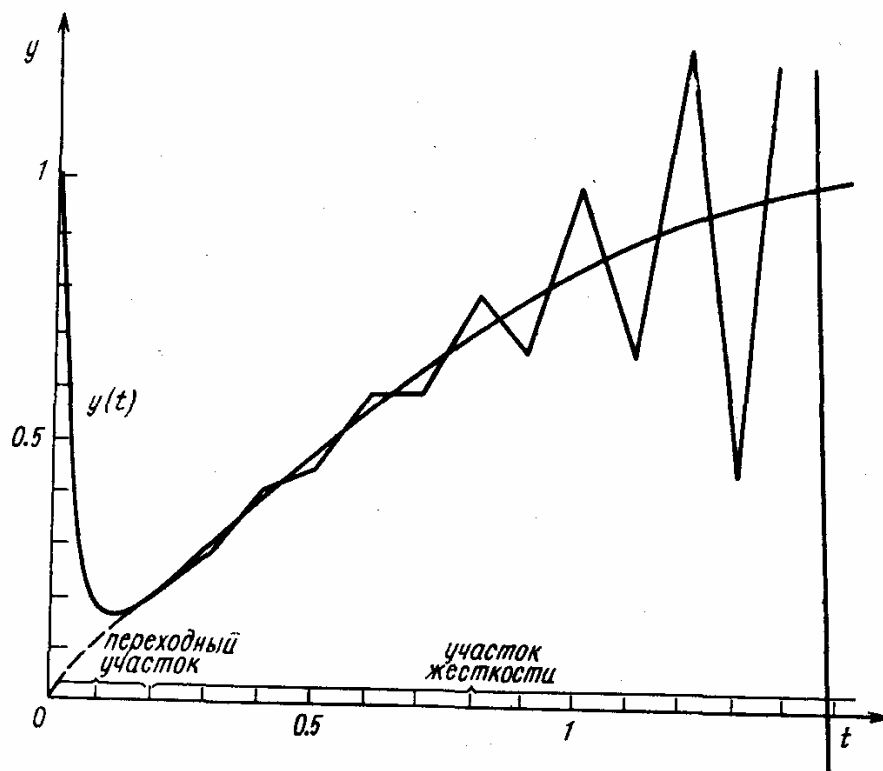


Рис. 14.16

Естественно, что приближенное решение на переходном участке приходится вычислять, используя достаточно мелкий шаг. Однако при  $t \gtrsim 0.2$ , когда переходная часть решения, казалось бы, уже практически отсутствует, возникает желание перейти к вычислению со сравнительно крупным шагом.

Предположим, что при  $t = 0.2$  найдено значение решения  $y(0.2) \approx 0.205$  с точностью  $\epsilon = 10^{-3}$ . Возьмем шаг  $h = 0.1$  и будем вычислять решение при  $t \geq 0.2$ , используя метод Эйлера:

$$y_{n+1} = y_n + h(-25y_n + \cos t_n + 25\sin t_n).$$

Полученные значения приближений и точные значения решения приведены в первых трех столбцах табл. 14.6. Соответствующая ломаная Эйлера изображена на рис. 14.16. Как нетрудно видеть, метод ведет себя неустойчивым образом и оказывается непригодным для решения рассматриваемой задачи при значении шага  $h = 0.1$ . На конкретном примере мы убедились в том, что условие абсолютной устойчивости (14.95) нарушать нельзя. В рассматриваемом случае  $\lambda = -25$  и это условие равносильно требованию  $h \leq 0.08$ . Взяв удовлетворяющий этому условию шаг  $h = 0.025$ , получим вполне приемлемое решение (см. табл. 14.6).

Т а б л и ц а 14.6

$t$	Точное решение	Метод Эйлера; $h = 0.1$	Метод Эйлера; $h = 0.025$	Неявный метод Эйлера; $h = 0.1$	Неявный метод Эйлера; $h = 0.3$
0.2	0.205	0.205	0.205	0.205	0.205
0.3	0.296	0.287	0.296	0.304	
0.4	0.389	0.404	0.390	0.391	
0.5	0.479	0.460	0.480	0.479	0.478
0.6	0.565	0.597	0.565	0.564	
0.7	0.644	0.600	0.644	0.643	
0.8	0.717	0.787	0.718	0.716	0.714
0.9	0.783	0.683	0.784	0.782	
1.0	0.841	0.996	0.842	0.840	
1.1	0.891	0.664	0.892	0.890	0.886
1.2	0.932	1.277	0.932	0.930	
1.3	0.964	0.451	0.964	0.962	
1.4	0.985	1.759	0.986	0.984	0.980
1.5	0.997	-0.158	0.996	0.996	

Попробуем теперь воспользоваться для решения задачи (14.128) неявным методом Эйлера:

$$y_{n+1} = y_n + h(-25y_{n+1} + \cos t_{n+1} + 25\sin t_{n+1}).$$

Напомним, что он  $A$ -устойчив и, следовательно, абсолютно устойчив для всех значений  $h$ . Используя для нахождения решения формулу

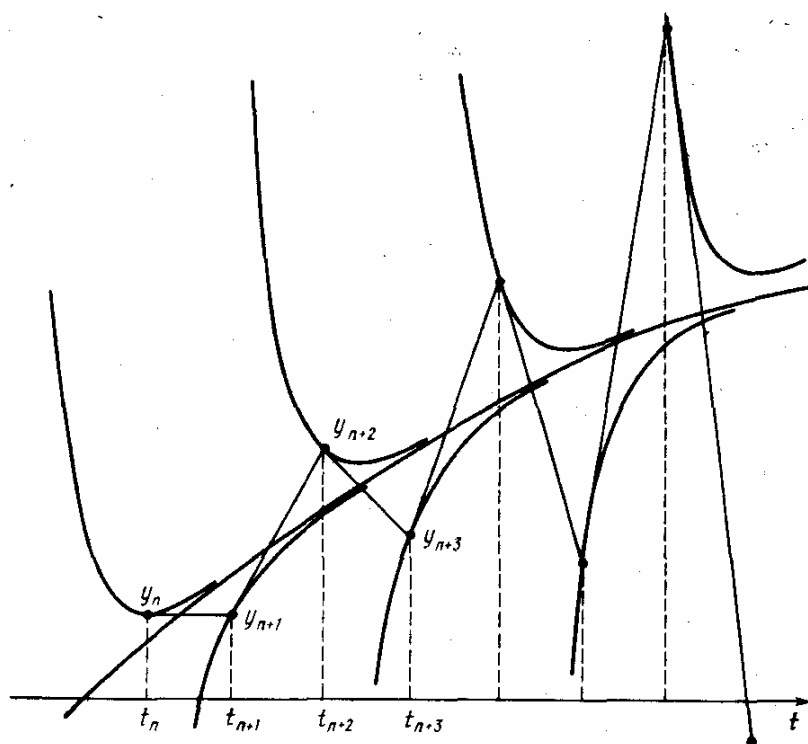


Рис. 14.17

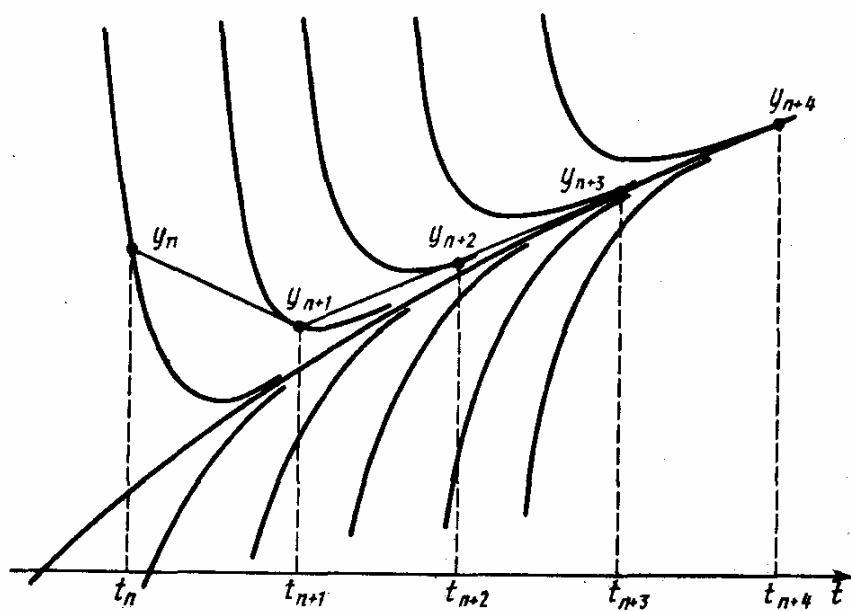


Рис. 14.18



$$y_{n+1} = \frac{y_n + h(\cos t_{n+1} + 25 \sin t_{n+1})}{1 + 25h},$$

при  $h = 0.1$  получим значения, совпадающие с соответствующими значениями решения с точностью  $2 \cdot 10^{-3}$  (см. табл. 14.6). Если же нас устраивает точность  $\epsilon = 6 \cdot 10^{-3}$ , то шаг  $h$  можно утроить. Вычисленные с шагом  $h = 0.3$  значения также указаны в табл. 14.6.

Приведенная в примере ситуация типична для жестких задач. При использовании классических явных методов наличие в решении быстро меняющийся *жесткой компоненты* даже на том участке, где ее значение пренебрежимо мало, заставляет выбирать шаг  $h$  из условия абсолютной устойчивости. Для жестких задач это ограничение приводит к неприемлемо малому значению шага  $h$ . Поэтому численное решение таких задач требует применения специальных неявных методов. Простейшим из них является неявный метод Эйлера. На рис. 14.17 и 14.18 проиллюстрировано принципиальное отличие результатов вычислений, осуществляемых с помощью явного и неявного методов Эйлера.

**2. Жесткие задачи для систем дифференциальных уравнений.** Рассмотрим задачу Коши для системы линейных дифференциальных уравнений с постоянными коэффициентами

$$y'(t) = Ay(t). \quad (14.129)$$

Предположим, что  $A$  — матрица простой структуры и все собственные числа этой матрицы имеют отрицательные вещественные части ( $\operatorname{Re} \lambda_m \leq \operatorname{Re} \lambda_{m-1} \leq \dots \leq \operatorname{Re} \lambda_1 < 0$ ). Как отмечалось в предыдущем параграфе, в этом случае решение задачи асимптотически устойчиво и представляется в виде

$$y(t) = c_1 e^{\lambda_1(t-t_0)} e_1 + c_2 e^{\lambda_2(t-t_0)} e_2 + \dots + c_m e^{\lambda_m(t-t_0)} e_m.$$

Если среди собственных чисел  $\lambda_i$  имеются числа с сильно различающимися значениями вещественных частей, то возникает проблема, связанная с наличием в решении  $y$  компонент, имеющих существенно

различные временные постоянные  $\tau_i = \frac{1}{|\operatorname{Re} \lambda_i|}$ . Через довольно короткий интервал времени поведение решения будет определяться наиболее слабо меняющейся (*медленной*) компонентой решения. Так, если  $\operatorname{Re} \lambda_m \leq \dots \leq \operatorname{Re} \lambda_2 < \operatorname{Re} \lambda_1 < 0$ , то при  $t - t_0 \gg \tau_2 = \frac{1}{|\operatorname{Re} \lambda_2|}$  справедливо

приближенное равенство  $y(t) \approx c_1 e^{\lambda_1(t-t_0)} e_1$ . В то же время применя-

емый для решения задачи Коши метод должен обладать свойствами устойчивости, позволяющими подавлять наиболее быстро меняющуюся (жесткую) компоненту  $c_m e^{\lambda_m(t-t_0)} e_m$  погрешности

$$\varepsilon(t) = \alpha_1 e^{\lambda_1(t-t_0)} e_1 + \alpha_2 e^{\lambda_2(t-t_0)} e_2 + \dots + \alpha_m e^{\lambda_m(t-t_0)} e_m.$$

Отметим, что для медленной компоненты решения временной постоянной является величина  $(\min_{1 \leq k \leq n} |\operatorname{Re} \lambda_k|)^{-1}$ , а для жесткой компоненты

погрешности — величина  $(\max_{1 \leq k \leq n} |\operatorname{Re} \lambda_k|)^{-1}$ . Их отношение и определяет

степень жесткости задачи.

Приведем применительно к системе (14.129) одно из определений жесткости. Пусть  $\operatorname{Re} \lambda_k < 0$  для всех  $k = 1, \dots, m$ . Определим число жесткости системы (14.129) с помощью формулы

$$s = \frac{\max_{1 \leq k \leq n} |\operatorname{Re} \lambda_k|}{\min_{1 \leq k \leq n} |\operatorname{Re} \lambda_k|}. \quad (14.130)$$

Систему уравнений (14.129) назовем *жесткой*, если для нее  $s \gg 1$ .

**Пример 14.23.** Рассмотрим систему

$$\begin{aligned} y' &= -7501y - 2499z, \\ z' &= -7497y - 2503z, \\ y(0) &= 0, \quad z(0) = 4. \end{aligned}$$

Собственные значения матрицы коэффициентов

$$A = \begin{bmatrix} -7501 & -2499 \\ -7497 & -2503 \end{bmatrix}$$

таковы:  $\lambda_1 = -4$ ,  $\lambda_2 = -10000$ . Здесь число жесткости  $s = \frac{|\lambda_2|}{|\lambda_1|} = 2500$  много больше единицы и поэтому систему можно квалифицировать как жесткую.

Общее решение системы имеет вид

$$y(t) = c_1 e^{-4t} + c_2 e^{-10000t}, \quad z(t) = c_1 e^{-4t} - 3c_2 e^{-10000t}.$$

Начальным значениям  $y(0) = 0$ ,  $z(0) = 4$  отвечает решение

$$y(t) = -e^{-4t} + e^{-10000t}, \quad z(t) = 3e^{-4t} + e^{-10000t}.$$

Жесткая компонента решения здесь быстро затухает и через очень небольшой интервал времени решение будет практически совпадать с  $\tilde{y}(t) = -e^{-4t}$ ,  $\tilde{z}(t) = 3e^{-4t}$ .

Решение этой задачи с помощью явных методов очень неэффективно. Например, для метода Рунге—Кутты четвертого порядка точности условие устойчивости  $h \lesssim \frac{2.8}{\max |\operatorname{Re} \lambda_k|}$  в данном случае приводит к необходимости использования очень мелкого шага  $h < 2.8 \cdot 10^{-4}$ .

**З а м е ч а н и е.** В приведенном выше наиболее простом определении жесткости требовалось, чтобы  $\operatorname{Re} \lambda_k < 0$  для всех  $k$ . Более общие современные определения жесткости [9], [26] не исключают наличия собственных чисел  $\lambda_i$  с положительными вещественными частями при условии, что для них  $\operatorname{Re} \lambda_i \ll \max_{1 \leq k \leq m} |\operatorname{Re} \lambda_k|$ .

В случае, когда матрица  $A$  зависит от  $t$  (т.е. решается система линейных уравнений с переменными коэффициентами), число жесткости также зависит от  $t$  и определяется по формуле (14.130), в которой уже  $\lambda_k = \lambda_k(t)$ . Так как  $s = s(t)$ , то система  $y' = A(t)y$  может оказаться жесткой на одном интервале времени  $t$  и нежесткой — на другом.

В настоящее время нет общепринятого математически корректного определения жесткости задачи Коши для системы нелинейных уравнений

$$y' = f(t, y). \quad (14.131)$$

Чаще всего эту задачу называют жесткой в окрестности точки  $(\tilde{t}, y(\tilde{t}))$ , если жесткой является соответствующая линеаризованная система

$$y'(t) = Ay(t), \quad A = f'_y(\tilde{t}, y(\tilde{t})). \quad (14.132)$$

В подтверждение правомерности такого определения жесткости можно сослаться на то, что (см. предыдущий параграф) погрешность  $\epsilon(t)$  решения нелинейной системы удовлетворяет приближенному равенству  $\epsilon'(t) \approx A\epsilon(t)$  и поэтому в малой окрестности точки  $(\tilde{t}, y(\tilde{t}))$  погрешности решений линеаризованной системы (14.132) и системы (14.131) должны вести себя примерно одинаковым образом.

К счастью, для того чтобы распознать жесткую задачу на практике, часто совсем не обязательно проводить математически строгое ее исследование. Если система уравнений (14.131) правильно моделирует

реальное физическое явление, включающее процессы с существенно различными временными постоянными, то соответствующая задача Коши должна быть жесткой. Как правило, исследователь проявляет интерес к изучению поведения медленно меняющихся характеристик процесса в течение длительного времени. Наличие же быстро меняющихся физических компонент при использовании классических явных методов решения задачи Коши заставляет его выбирать шаг  $h$  порядка наименьшей из временных постоянных, что делает процесс численного решения чрезвычайно дорогостоящим и неэффективным. Существующие в настоящее время методы решения жестких задач позволяют использовать шаг  $h$  порядка наибольшей из временных постоянных, подчиняя его выбор только требованию точности.

**З а м е ч а н и е 1.** В последнее время задачу не принято квалифицировать как жесткую на переходном участке. Если исследователь проявляет интерес к изучению переходного режима, то для нахождения решения на переходном участке могут оказаться вполне приемлемыми и явные методы Рунге—Кутты и Адамса.

**З а м е ч а н и е 2.** Обычно при определении жесткости делается явное или неявное предположение о том, что среди собственных чисел матрицы  $A$  отсутствуют такие, для которых  $|\operatorname{Im} \lambda_i| \gg 1$ . Это означает, что предполагается отсутствие быстрых осцилляций в компонентах погрешности. Если же такие осцилляции возможны, то необходимо использовать специальные методы подавления соответствующих компонент погрешности.

**3. Понятие о методах решения жестких задач.** Для решения жестких задач было бы желательно использовать  $A$ -устойчивые методы, так как они не накладывают никаких ограничений на шаг  $h$ . Однако оказывается, что класс таких методов весьма узок. Например, среди явных линейных многошаговых методов нет  $A$ -устойчивых. Доказано также, что среди неявных линейных многошаговых методов нет  $A$ -устойчивых методов, имеющих порядок точности выше второго.

Многие из возникающих на практике жестких задач таковы, что для них собственные значения матрицы Якоби удовлетворяют неравенству  $|\arg(-\lambda_i)| < \alpha$  ( $i = 1, 2, \dots, m$ ), где  $\alpha > 0$  — некоторое число. В частности, если все собственные значения вещественны и отрицательны, то указанное неравенство выполняется для любого сколь угодно малого  $\alpha > 0$ .

Для таких задач требование  $A$ -устойчивости методов является чрезмерным и его можно заменить менее ограничительным требованием наличия у метода  $A(\alpha)$ -устойчивости. Численный метод решения

задачи Коши называют  $A(\alpha)$ -устойчивыми, если область его абсолютной устойчивости включает угол  $|\arg(-z)| < \alpha$  (рис. 14.19). В частности, при  $\alpha = \pi/2$  определение  $A(\alpha)$ -устойчивости совпадает с определением  $A$ -устойчивости.

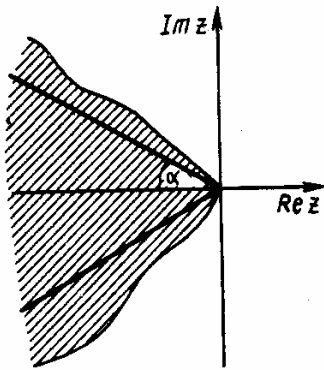


Рис. 14.19

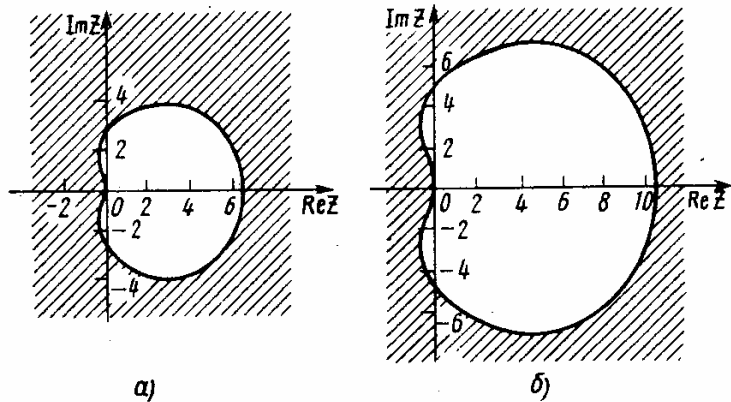


Рис. 14.20

Известно, что среди явных линейных многошаговых методов нет  $A(\alpha)$ -устойчивых ни при каком  $\alpha > 0$ . Однако среди неявных линейных многошаговых методов имеются  $A(\alpha)$ -устойчивые методы высокого порядка точности. Важный класс таких методов (формул дифференцирования назад) относится к так называемым *чисто неявным методам*:

$$\frac{1}{h} \sum_{j=0}^n \alpha_j y_{n+1-j} = f(t_{n+1}, y_{n+1}).$$

Чисто неявные методы получаются в результате замены в системе дифференциальных уравнений (14.131) при  $t = t_{n+1}$  производной  $y'(t)$  ее разностной аппроксимацией, использующей значения функции в точках  $t_{n+1}, t_n, \dots, t_{n+1-k}$ . Если для этого используется односторонняя разностная производная (см. § 12.2), то получается *формула дифференцирования назад*.

Приведем формулы дифференцирования назад при  $k = 1, 2, 3, 4$ , имеющие  $k$ -й порядок точности

$$\frac{y_{n+1} - y_n}{h} = f(t_{n+1}, y_{n+1}), \quad k = 1 \quad (14.133)$$

(это неявный метод Эйлера);

$$\frac{3y_{n+1} - 4y_n + y_{n-1}}{2h} = f(t_{n+1}, y_{n+1}), \quad k = 2; \quad (14.134)$$

$$\frac{11y_{n+1} - 18y_n + 9y_{n-1} - 2y_{n-2}}{6h} = f(t_{n+1}, y_{n+1}), k = 3; \quad (14.135)$$

$$\frac{25y_{n+1} - 48y_n + 36y_{n-1} - 16y_{n-2} + 3y_{n-3}}{12h} = f(t_{n+1}, y_{n+1}), k = 4. \quad (14.136)$$

Напомним, что метод (14.133) является  $A$ -устойчивым. Как видно из рис. 14.20, *a* и 14.20, *б*, для формул (14.134) и (14.135) области их абсолютной устойчивости почти целиком содержат левую полуплоскость  $\operatorname{Re} z < 0$ . Поэтому свойства устойчивости<sup>1</sup> этих методов вполне достаточны для решения большинства жестких задач.

Весьма популярный и широко используемый при решении жестких задач алгоритм Гира основан на использовании формул дифференцирования назад порядка точности  $k = 1, 2, \dots, 6$  и представляет собой метод с автоматическим выбором шага интегрирования и порядка метода. Один из первых вариантов алгоритма реализован в фортранной программе DIFSUB.

## § 14.12. Дополнительные замечания

1. К настоящему времени разработано большое число различных численных методов решения задачи Коши и работа в этом направлении ведется очень активно. Тем не менее наиболее популярными остаются классические методы Рунге—Кутты и Адамса, а также их современные модификации. Каждый из этих двух классов методов имеет определенные достоинства и недостатки, некоторые из них уже обсуждались выше. Не имея перед собой конкретной задачи, вряд ли можно дать рекомендации в пользу того или иного метода, тем более что до сих пор в этом вопросе нет достаточной ясности. Однако ориентируясь на серьезное обсуждение оценки качества методов, приведенное в книге [74], можно попытаться грубо описать ситуации, в которых они обладают большей эффективностью. При этом следует иметь в виду, что одним из основных показателей эффективности метода является количество вычислений правых частей дифференциальных уравнений, которое требуется для достижения заданной точности решения.

Предположим, что решаемая задача Коши не является жесткой. Предположим также, что вычисление правых частей дифференциальных уравнений не является слишком трудоемкой операцией. Тогда целесообразно применение методов Рунге—Кутты с автоматическим выбором шага, наиболее эффективным среди которых для широкого класса задач является метод Рунге—Кут-

---

<sup>1</sup> При  $1 \leq k \leq 6$  формулы дифференцирования назад обладают так называемой жесткой устойчивостью [68], [74].

ты—Фельберга пятого порядка точности. Если же к точности решения не предъявляются слишком высокие требования, то хороший результат следует ожидать и от применения классического метода Рунге—Кутты четвертого порядка точности.

В том случае, когда вычисления правых частей трудоемки (на каждую из них приходится в среднем более 25 арифметических операций) имеет смысл предпочесть использование качественной программы, реализующей метод Адамса с автоматическим выбором шага и порядка метода. По-видимому, именно эти методы в будущем станут наиболее употребительными.

2. После того как приближенные значения  $y_n$  решения задачи Коши в узлах  $t_n$  ( $n = 0, 1, \dots, N$ ) определены, для вычисления значений решения  $y(t)$  в промежуточных точках можно использовать интерполяцию. В связи с этим полезно отметить, что наряду со значениями вектор-функции  $y_n$  фактически оказываются вычисленными значения производной  $y'_n = f(t_n, y_n)$ . Поэтому в данном случае для интерполяции естественно использование кубического интерполяционного многочлена Эрмита или локального кубического сплайна (см. гл. 11). Для методов первого или второго порядка точности вполне удовлетворительный результат дает использование линейной интерполяции.

3. Поиск эффективных методов решения жестких задач еще находится в начальной стадии. Тем не менее разработан ряд популярных алгоритмов (среди которых наиболее известен алгоритм Гира) и создано значительное число качественных программ. Вопрос о наиболее эффективном методе решения жестких задач остается открытым и какие-либо рекомендации здесь преждевременны. В последнее время выявилась достаточная перспективность применения для решения таких задач специальных неявных методов Рунге—Кутты [26]. Подчеркнем еще раз, что явные методы Рунге—Кутты для этой цели совершенно непригодны.

4. Дополнительную информацию о методах решения задачи Коши (и полезное обсуждение жестких задач) можно найти, например, в учебниках [9], [14], [43], [60], [69], [71], [86]. Настоятельно советуем обратить внимание на две весьма содержательные книги [74] и [88]. Вторая из них содержит систематическое и доступное широкому кругу читателей изложение численных методов решения нежестких задач. Методам решения жестких задач специально посвящены монографии [68], [26], последняя из которых содержит современный взгляд на эту проблему.

## Глава 15

### РЕШЕНИЕ ДВУХТОЧЕЧНЫХ КРАЕВЫХ ЗАДАЧ

*Двухточечная краевая задача* — это задача отыскания решения обыкновенного дифференциального уравнения или системы обыкновенных дифференциальных уравнений на отрезке  $a \leq x \leq b$  при условии, что дополнительные условия на решение налагаются в двух точках  $a$  и  $b$  — "краях" отрезка  $[a, b]$  (отсюда — и название задачи).

Решить краевую задачу, вообще говоря, значительно труднее, чем задачу Коши и для этого используются разнообразные подходы. Наиболее распространены различные методы дискретизации, позволяющие заменить исходную задачу некоторым ее дискретным аналогом. Получающаяся дискретная краевая задача представляет собой систему уравнений (возможно, нелинейных) с конечным числом неизвестных и может быть решена на ЭВМ с помощью специальных прямых или итерационных методов. Одним из простейших и весьма популярных подходов к дискретизации является использование метода конечных разностей. В §§ 15.2 и 15.3 рассматриваются некоторые из основных моментов применения этого метода.

В § 15.4 дается представление о другом подходе к дискретизации краевых задач. В нем описываются проекционные методы Ритца и Галеркина и обсуждается один из их современных вариантов, имеющий большое практическое значение, — метод конечных элементов.

В заключение главы рассматривается метод пристрелки.

#### § 15.1. Краевые задачи для одномерного стационарного уравнения теплопроводности

1. Дифференциальное уравнение и краевые условия. Рассмотрим дифференциальное уравнение второго порядка

$$-\frac{d}{dx} \left( k(x) \frac{du}{dx} \right) + q(x) u = f(x), \quad a \leq x \leq b. \quad (15.1)$$



Оно называется *одномерным стационарным уравнением теплопроводности* и возникает при математическом моделировании многих важных процессов. Например, это уравнение описывает установившееся распределение температуры  $u(x)$  в теплопроводящем стержне длины  $l = b - a$ . В этом случае  $k(x)$  — коэффициент теплопроводности;  $w(x) = -k(x) \frac{du}{dx}$  — плотность потока тепла;  $q(x)$  — коэффициент теплоотдачи ( $qu$  — мощность стоков тепла, пропорциональная температуре  $u$ );  $f(x)$  — плотность источников тепла (при  $f \leq 0$  — плотность стоков тепла).

Уравнение (15.1) описывает также установившееся распределение плотности нейтронов в реакторе, характеристики которого зависят от одной пространственной переменной  $x$ . В такой трактовке  $u(x)$  — это полный поток нейтронов,  $k(x)$  — коэффициент диффузии,  $q(x)$  — сечение поглощения,  $f(x)$  — плотность источников нейтронов. То же уравнение описывает и стационарные процессы диффузии газов (растворов) в пористых средах;  $u(x)$  рассматривается тогда как концентрация диффундирующего вещества. Поэтому уравнение (15.1) часто называют *одномерным уравнением диффузии*. Рассматриваемое уравнение имеет приложения и в других областях техники и естествознания (деформации струн и стержней, распространение электромагнитных волн и т. д.)

Далее будем считать функции  $k(x)$ ,  $q(x)$ ,  $f(x)$  заданными и предполагать, что выполнены неравенства

$$k(x) \geq k_0 > 0, \quad q(x) \geq 0. \quad (15.2)$$

Так как уравнение (15.1) является дифференциальным уравнением второго порядка, то для того чтобы однозначно найти функцию  $u(x)$  — распределение температуры в стержне, необходимо задать два дополнительных условия. Простейшая постановка краевых условий такова:

$$u(a) = u_a, \quad u(b) = u_b.$$

Краевые условия такого типа принято называть *краевыми условиями первого рода*. Физическая интерпретация этих краевых условий состоит в том, что в рассматриваемой задаче на торцах стержня поддерживаются фиксированные значения температуры  $u_a$  и  $u_b$ .

Возможны и другие постановки краевых условий. Так, если известна плотность потока тепла через левый торец стержня, то условие  $u(a) = u_a$  можно заменить *краевым условием второго рода*:

$$-k(a) u'(a) = w_a.$$

Аналогичное условие для правого торца имеет вид

$$-k(b) u'(b) = w_b.$$

Основное внимание в этой главе будет уделено краевой задаче

$$L[u](x) = f(x), \quad a < x < b, \quad (15.3)$$

$$u(a) = u_a, \quad u(b) = u_b. \quad (15.4)$$

Здесь  $L$  — дифференциальный оператор, определяемый следующим образом:

$$L[u](x) = -(k(x) u'(x))' + q(x)u(x).$$

**2. Разрешимость краевой задачи.** Будем считать, что коэффициенты  $q$  и  $f$  непрерывны на отрезке  $[a, b]$ , коэффициент  $k$  непрерывно дифференцируем на  $[a, b]$  и выполнены условия (15.2).

Назовем дважды непрерывно дифференцируемую на отрезке  $[a, b]$  функцию  $u(x)$  *решением (классическим решением) краевой задачи* (15.3), (15.4), если  $u(x)$  является решением дифференциального уравнения (15.3) и удовлетворяет краевым условиям (15.4).

Приведем без доказательства известные из теории дифференциальных уравнений результаты о разрешимости рассматриваемой краевой задачи и о гладкости ее решения.

**Теорема 15.1.** *Решение краевой задачи (15.3), (15.4) существует и единственно.*

**Теорема 15.2.** *Пусть коэффициенты  $q$  и  $f$  являются  $t$  раз, а коэффициент  $k$  —  $t + 1$  раз непрерывно дифференцируемыми на отрезке  $[a, b]$  функциями. Тогда решение  $u(x)$  краевой задачи (15.3), (15.4) есть непрерывно дифференцируемая  $t + 2$  раза на отрезке  $[a, b]$  функция.*

**3. Принцип максимума.** Важным свойством уравнения (15.3) является наличие так называемого *принципа максимума*. Приведем один из вариантов его формулировки.

**Теорема 15.3.** *Пусть  $u(x)$  — решение задачи (15.3), (15.4). Тогда если  $f(x) \leq 0$ ,  $u_a \leq 0$ ,  $u_b \leq 0$ , то  $u(x) \leq 0$ .*

Теорема 15.3 имеет простой физический смысл. Если отсутствуют источники тепла и температура торцов стержня неположительна, то ни в одной из внутренних точек стержня температура не может стать положительной.

Заметим, что произвольную дважды непрерывно дифференцируемую функцию  $u(x)$  можно рассматривать как решение краевой задачи (15.3), (15.4), если специальным образом выбрать правую часть  $f$  и краевые значения  $u_a$ ,  $u_b$ , а именно положить  $f(x) = L[u](x)$ ,  $u_a = u(a)$ ,  $u_b = u(b)$ . Учитывая это замечание, сформулируем теорему 15.3 иным образом.

**Теорема 15.4.** Пусть  $u(x)$  — дважды непрерывно дифференцируемая на отрезке  $[a, b]$  функция, удовлетворяющая неравенствам  $L[u] \leq 0$ ,  $u(a) \leq 0$ ,  $u(b) \leq 0$ . Тогда  $u(x) \leq 0$ .

Из теоремы 15.4 вытекает следующее утверждение.

**Теорема 15.5 (теорема сравнения).** Пусть  $u(x)$ ,  $v(x)$  — дважды непрерывно дифференцируемые на отрезке  $[a, b]$  функции, удовлетворяющие неравенствам  $L[u] \leq L[v]$ ,  $u(a) \leq v(a)$ ,  $u(b) \leq v(b)$ . Тогда  $u(x) \leq v(x)$ .

**4. Априорная оценка и устойчивость решения.** Используя теорему сравнения, можно вывести оценку максимума модуля решения  $u(x)$  через данные краевой задачи.

**Теорема 15.6.** Справедлива следующая оценка решения краевой задачи (15.3), (15.4):

$$\max_{[a, b]} |u(x)| \leq \max \{|u_a|, |u_b|\} + K \cdot \max_{[a, b]} |f(x)|. \quad (15.5)$$

Здесь  $K = \frac{Rl}{4}$ ,  $R = \int_a^b \frac{dx}{k(x)}$ ,  $l = b - a$ .

**З а м е ч а н и е 1.** Неравенства типа (15.5) принято называть априорными оценками решения.

**З а м е ч а н и е 2.** Если коэффициент  $k(x)$  рассматривать как коэффициент теплопроводности, то  $\frac{1}{k(x)}$  — это коэффициент тепло-

сопротивления, а  $R = \int_a^b \frac{dx}{k(x)}$  — это полное теплосопротивление стержня.

**З а м е ч а н и е 3.** При  $k(x) \equiv 1$  уравнение (15.3) принимает вид  $-u''(x) + q(x)u(x) = f(x)$ . (15.6)

В этом случае  $R = l$  и оценку (15.5) можно уточнить следующим образом:

$$\max_{[a, b]} |u(x)| \leq \max \{|u_a|, |u_b|\} + \frac{l^2}{8} \max_{[a, b]} |f(x)|. \quad (15.7)$$

Рассмотрим теперь вопрос о влиянии погрешностей задания крайних значений  $u_a$ ,  $u_b$  и правой части  $f$  на решение краевой задачи. Пусть  $u(x)$  — решение краевой задачи (15.3), (15.4), а  $u^*(x)$  — решение краевой задачи

$$L[u^*](x) = f^*(x), \quad a < x < b,$$

$$u^*(a) = u_a^*, \quad u^*(b) = u_b^*.$$

Здесь  $f^*(x)$  — непрерывная функция, рассматриваемая как приближенно заданная (с погрешностью  $\delta f^*(x) = f(x) - f^*(x)$ ) правая часть уравнения;  $u_a^*$ ,  $u_b^*$  — приближенно заданные (с погрешностями  $\varepsilon_a = u_a - u_a^*$ ,  $\varepsilon_b = u_b - u_b^*$ ) краевые значения.

**Т е о р е м а 15.7.** *Справедлива оценка*

$$\max_{[a, b]} |u(x) - u^*(x)| \leq \max \{|\varepsilon_a|, |\varepsilon_b|\} + K \cdot \max_{[a, b]} |\delta f(x)|, \quad (15.8)$$

где  $K$  — та же постоянная, что и в неравенстве (15.5).

□ Для доказательства достаточно заметить, что функция  $\varepsilon(x) = u(x) - u^*(x)$  является решением краевой задачи

$$L[\varepsilon](x) = \delta f(x), \quad a < x < b,$$

$$\varepsilon(a) = \varepsilon_a, \quad \varepsilon(b) = \varepsilon_b,$$

и воспользоваться для оценки величины  $\max_{[a, b]} |\varepsilon(x)|$  теоремой 15.6. ■

Из оценки (15.8) видно, что в случае, когда величина  $K$  не очень велика, краевая задача (15.3), (15.4) хорошо обусловлена. Если же  $K \gg 1$ , то задача является плохо обусловленной. В этом случае погрешности порядка  $\delta$  задания правой части уравнений может отвечать погрешность порядка  $K\delta$  решения задачи. Ниже при рассмотрении численных методов решения краевой задачи будем предполагать, что она хорошо обусловлена.

**З а м е ч а н и е.** Если рассматривается устойчивость решения краевой задачи для уравнения (15.6), то в оценке (15.8) следует заменить  $K$  на  $P/8$ .

## § 15.2. Метод конечных разностей:

### основные понятия

*Метод конечных разностей* (или *метод сеток*) является одним из универсальных и широко используемых методов решения краевых задач. Его популярность во многом объясняется относительной простотой подхода к дискретизации дифференциальных уравнений. Суть метода состоит в следующем. Область непрерывного изменения аргумента заменяют конечным (дискретным) множеством точек (узлов), называемым *сеткой*. Вместо функций непрерывного аргумента рассматривают функции, определенные только в узлах сетки, — *сеточные*

*функции*. Производные, которые входят в дифференциальное уравнение и краевые условия, заменяют их разностными аналогами — линейными комбинациями значений сеточных функций в некоторых узлах сетки. В результате краевую задачу заменяют *дискретной краевой задачей* (разностной схемой), представляющей собой систему конечного числа линейных или нелинейных алгебраических уравнений. Решение разностной схемы (предполагается, что оно существует) принимают за приближенное решение краевой задачи.

Несмотря на кажущуюся простоту метода, при его использовании приходится решать ряд проблем. Например, следует иметь в виду, что для одной краевой задачи можно построить большое число различных разностных схем, среди которых далеко не все пригодны для использования на практике.

В этом параграфе мы покажем, как применяется разностный метод для решения краевой задачи (15.3), (15.4), ограничиваясь для простоты изложения случаем уравнения с постоянным коэффициентом  $k(x) = 1$ . В этом случае краевая задача принимает вид

$$-u''(x) + q(x)u(x) = f(x), \quad a < x < b, \quad (15.9)$$

$$u(a) = u_a, \quad u(b) = u_b. \quad (15.10)$$

**1. Построение сетки и введение сеточных функций.** Произведем дискретизацию области непрерывного изменения аргумента  $x$ , заменив

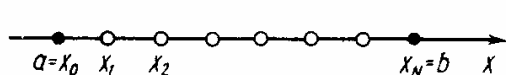


Рис. 15.1

отрезок  $[a, b]$  сеткой  $\bar{\omega}^h$  — конечным набором точек  $a = x_0 < x_1 < \dots < x_N = b$  (рис. 15.1). Точки  $x_i$  называются

*узлами сетки*  $\bar{\omega}^h$ .

Для простоты изложения в этом параграфе будем считать сетку равномерной с шагом  $h = (b - a)/N$ . Тогда  $x_i - x_{i-1} = h$  для всех  $i = 1, 2, \dots, N$ . Заметим, что при  $N \rightarrow \infty$  шаг  $h \rightarrow 0$  (сетка измельчается).

Сетка  $\bar{\omega}^h$  естественным образом разбивается здесь на два подмножества:  $\bar{\omega}^h = \omega^h \cup \gamma^h$ . Множество внутренних узлов  $\omega^h$  состоит из тех узлов  $x_i$ , ( $1 \leq i \leq N - 1$ ), которые лежат внутри интервала  $(a, b)$ . Множество граничных узлов  $\gamma^h$  состоит из двух узлов  $x_0 = a$  и  $x_N = b$ , лежащих на границе отрезка  $[a, b]$ .

Далее будем вычислять решение краевой задачи не в произвольных точках отрезка  $[a, b]$ , а только в узлах сетки  $\bar{\omega}^h$ . Таким образом, искомой окажется не функция  $u$ , а сеточная функция<sup>1</sup>  $u^h$ . Значения  $u^h(x_i)$

<sup>1</sup> Сеточные функции использовались нами и в предыдущей главе.

этой функции в узлах  $x_i$  будем обозначать через  $u_i$  и рассматривать как приближения к значениям  $u(x_i)$  решения задачи (15.9), (15.10). Введем также сеточные функции  $q^h$  и  $f^h$ , принимающие в узлах сетки  $\omega^h$  значения  $q_i = q(x_i)$  и  $f_i = f(x_i)$ .

**2. Построение разностной схемы.** Напомним (см. гл. 12), что производную  $u''(x)$  можно аппроксимировать второй разностной производной:

$$u''(x) \approx \frac{u(x-h) - 2u(x) + u(x+h)}{h^2} \quad (15.11)$$

с погрешностью  $r_h(x) = u^{(4)}(\xi) \frac{h^2}{12}$ , где  $\xi \in [x-h, x+h]$ . Используя формулу (15.11), заменим теперь в каждом из внутренних узлов  $x_i$  ( $1 \leq i \leq N-1$ ) дифференциальное уравнение (15.9) приближенным равенством

$$-\frac{u(x_{i-1}) - 2u(x_i) + u(x_{i+1}))}{h^2} + q_i u(x_i) \approx f_i, \quad 1 \leq i \leq N-1, \quad (15.12)$$

связывающим неизвестные значения решения в трех последовательных узлах сетки.

Потребуем теперь, чтобы значения искомой сеточной функции  $u^h$  удовлетворяли во всех внутренних узлах сетки уравнениям (15.12), в которых знак приближенного равенства заменен на знак равенства:

$$-\frac{u^h(x_{i-1}) - 2u^h(x_i) + u^h(x_{i+1}))}{h^2} + q_i u^h(x_i) = f_i, \quad 1 \leq i \leq N-1. \quad (15.13)$$

В результате дифференциальное уравнение (15.9) оказалось аппроксимированным его дискретным аналогом — *разностным уравнением* (15.13).

Естественно потребовать, чтобы в граничных узлах сеточная функция  $u^h$  удовлетворяла равенствам

$$u^h(x_0) = u_a, \quad u^h(x_N) = u_b. \quad (15.14)$$

Таким образом, мы пришли к системе линейных алгебраических уравнений (15.13), (15.14), в которой число уравнений совпадает с числом неизвестных  $u_i = u^h(x_i)$  ( $i = 0, 1, \dots, N$ ) и равно  $N+1$ . Решая эту систему (которую мы будем называть *системой сеточных уравнений*), можно найти сеточную функцию  $u^h$ .

Введем линейный разностный оператор  $L^h$  с помощью равенства

$$L^h[u^h](x_i) = -\frac{u^h(x_{i-1}) - 2u^h(x_i) + u^h(x_{i+1}))}{h^2} + q_i u^h(x_i), \quad x_i \in \omega^h$$

и запишем систему сеточных уравнений (15.13), (15.14) в следующем виде:

$$L^h[u^h](x) = f^h(x), \quad x \in \omega^h \quad (15.15)$$

$$u^h(x_0) = u_a, \quad u^h(x_N) = u_b \quad (15.16)$$

Дискретную задачу (15.15), (15.16), зависящую от параметра  $h$ , принято называть *разностной схемой для краевой задачи* (15.9), (15.10).

**3. Вычисление решения разностной схемы с помощью метода прогонки.** Приведем систему сеточных уравнений к виду

$$-u_{i-1} + (2 + h^2 q_i)u_i - u_{i+1} = h^2 f_i, \quad 1 \leq i \leq N-1, \quad (15.17)$$

$$u_0 = u_a, \quad u_N = u_b \quad (15.18)$$

Как нетрудно видеть, эта система есть частный случай системы линейных алгебраических уравнений вида

$$b_0 u_0 + c_0 u_1 = d_0,$$

$$a_i u_{i-1} + b_i u_i + c_i u_{i+1} = d_i, \quad 1 \leq i \leq N-1,$$

$$a_N u_{N-1} + b_N u_N = d_N$$

матрица которой трехдиагональна. Здесь

$$a_i = -1, \quad b_i = 2 + h^2 q_i, \quad c_i = -1, \quad d_i = h^2 f_i, \quad 1 \leq i < N, \quad (15.19)$$

$$b_0 = 1, \quad c_0 = 0, \quad d_0 = u_a, \quad a_N = 0, \quad b_N = 1, \quad d_N = u_b.$$

Напомним, что эффективным методом решения таких систем является метод прогонки (см. § 5.9), вычисления которого состоят из двух этапов: прямого и обратного хода.

Прямой ход метода прогонки заключается в вычислении прогоночных коэффициентов  $\alpha_i$  и  $\beta_i$  ( $0 \leq i \leq N$ ). При  $i = 0$  коэффициенты вычисляются по формулам

$$\alpha_0 = -c_0/\gamma_0, \quad \beta_0 = d_0/\gamma_0, \quad \gamma_0 = b_0,$$

а при  $i = 1, 2, \dots, N-1$  — по рекуррентным формулам

$$\alpha_i = -c_i/\gamma_i, \quad \beta_i = (d_i - a_i \beta_{i-1})/\gamma_i, \quad \gamma_i = b_i + a_i \alpha_{i-1}.$$

При  $i = N$  прямой ход завершают вычислением значения

$$\beta_N = (d_N - a_N \beta_{N-1})/\gamma_N, \quad \gamma_N = b_N + a_N \alpha_{N-1}.$$

Обратный ход метода прогонки дает значения неизвестных. Сначала полагают  $u_N = \beta_N$ , а затем значения остальных неизвестных находят по формуле

$$u_i = \alpha_i u_{i+1} + \beta_i.$$

Вычисления ведут в порядке убывания значений индекса  $i$  от  $N - 1$  до 0.

Применительно к решению системы (15.17), (15.18) расчетные формулы метода прогонки упрощаются.

Прогоночные коэффициенты вычисляют по формулам

$$\begin{aligned} \alpha_0 &= 0, \quad \beta_0 = u_a, \\ \alpha_i &= 1/\gamma_i, \quad \beta_i = (h^2 f_i + \beta_{i-1})/\gamma_i, \quad \gamma_i = 2 + h^2 q_i - \alpha_{i-1}, \end{aligned} \quad (15.20)$$

где  $i = 1, 2, \dots, N - 1$ .

Обратный ход дает значения неизвестных  $u_1, u_2, \dots, u_{N-1}$  (напомним, что значения  $u_0 = u_a, u_N = u_b$  известны). Для этого производят вычисления по формулам

$$u_N = u_b, \quad (15.21)$$

$$u_i = \alpha_i u_{i+1} + \beta_i, \quad i = N - 1, N - 2, \dots, 1. \quad (15.22)$$

**З а м е ч а н и е.** Очевидно, что коэффициенты (15.19) удовлетворяют неравенствам

$$a_i \leq 0, \quad b_i > 0, \quad c_i < 0, \quad a_i + b_i + c_i \geq 0, \quad 1 \leq i < N \quad (15.23)$$

Отсюда следует, что для системы (15.17), (15.18) выполнены условия диагонального преобладания:  $|b_0| \geq |c_0|$ ,  $|b_i| \geq |a_i| + |c_i| > |a_i|$  ( $1 \leq i < N$ ),  $|b_N| > |a_N|$ . Поэтому в силу теоремы 5.4 вычисления по формулам (15.20) могут быть доведены до конца (ни один из знаменателей  $\gamma_i$  не обратится в нуль). Кроме того, обратная прогонка устойчива по входным данным.

**4. Существование и единственность решения.** Согласно последнему замечанию, систему сеточных уравнений (15.17), (15.18) с помощью эквивалентных преобразований можно привести к системе вида (15.21), (15.22), из которой однозначно находятся неизвестные. Таким образом, справедлива следующая теорема.

**Т е о р е м а 15.8.** *Решение разностной схемы (15.15), (15.16) существует и единственно.*

Как будет показано ниже, разностная схема (15.15), (15.16) обладает рядом свойств, аналогичных соответствующим свойствам краевой задачи (15.9), (15.10).

**5. Принцип максимума.** Как уже отмечалось ранее, важным свойством задачи (15.9), (15.10) является принцип максимума. Естественно



потребовать, чтобы и для разностной схемы был справедлив дискретный аналог этого свойства. Более того, невыполнение для разностной схемы принципа максимума можно рассматривать как серьезный дефект, ставящий под сомнение возможность ее использования на практике.

**Л е м м а 15.1** (принцип максимума для системы сеточных уравнений). Пусть сеточная функция  $u^h$  является решением системы сеточных уравнений

$$\begin{aligned} a_i u_{i-1} + b_i u_i + c_i u_{i+1} &= d_i, \quad 1 \leq i < N, \\ u_0 &= u_a, \quad u_N = u_b \end{aligned} \quad (15.24)$$

коэффициенты которой удовлетворяют условиям (15.23). Тогда если  $u_a \leq 0$ ,  $u_b \leq 0$  и  $d_i \leq 0$  для всех  $i = 1, 2, \dots, N-1$ , то  $u^h \leq 0$ .

□ Предположим, что неравенство  $u^h \leq 0$  не выполнено. Так как по условию значения  $u^h$  в граничных узлах неотрицательны ( $u_0 = u_a \leq 0$ ,  $u_N = u_b \leq 0$ ), то максимальное значение функции  $u^h$  положительно и достигается во внутреннем узле сетки:  $u_{\max} = \max_{1 \leq i < N} u_i > 0$ .

Пусть  $j$  — максимальный среди индексов  $i$ , для которых  $u_i = u_{\max}$ . В силу такого выбора  $j$  справедливы неравенства  $u_{j-1} \leq u_j = u_{\max}$ ,  $u_{j+1} < u_j = u_{\max}$ . Так как  $a_j \leq 0$ ,  $c_j < 0$ , то  $a_j u_j \leq a_j u_{j-1}$ ,  $c_j u_j < c_j u_{j+1}$ . Учитывая, что  $a_j + b_j + c_j \geq 0$ ,  $d_j \leq 0$ , из равенства (15.24), взятого при  $i = j$ , получим следующую цепочку неравенств:

$$0 \leq (a_j + b_j + c_j) u_j < a_j u_{j-1} + b_j u_j + c_j u_{j+1} = d_j \leq 0$$

Полученное противоречие ( $0 < 0$ ) доказывает, что  $u^h \leq 0$ . ■

**Т е о р е м а 15.9** (принцип максимума). Пусть сеточная функция  $u^h$  является решением разностной схемы (15.15), (15.16). Тогда если  $f^h \leq 0$ ,  $u_a \leq 0$ ,  $u_b \leq 0$ , то  $u^h \leq 0$ .

□ Для доказательства достаточно заметить, что коэффициенты соответствующей системы сеточных уравнений (15.17), (15.18) удовлетворяют условиям (15.23),  $d_i = h^2 f_i \leq 0$ , и воспользоваться леммой 15.1. ■

Заметим, что произвольную сеточную функцию  $u^h$  можно считать решением разностной схемы (15.15), (15.16), если выбрать правую часть и граничные значения специальным образом, а именно положить  $f^h = L^h[u^h]$ ,  $u_a = u^h(x_0)$ ,  $u_b = u^h(x_N)$ . Учитывая это замечание, сформулируем теорему 15.9 иным образом:

**Т е о р е м а 15.10.** Пусть сеточная функция  $u^h$  удовлетворяет неравенствам  $L^h[u^h] \leq 0$ ,  $u^h(x_0) \leq 0$ ,  $u^h(x_N) \leq 0$ . Тогда  $u^h \leq 0$ .

Из этой теоремы вытекает следующий важный результат.

**Теорема 15.11 (теорема сравнения).** Пусть сеточные функции  $u^h$  и  $v^h$  удовлетворяют неравенствам  $|L^h[u^h]| \leq L^h[v^h]$ ,  $|u^h(x_0)| \leq v^h(x_0)$ ,  $|u^h(x_N)| \leq v^h(x_N)$ . Тогда  $|u^h| \leq v^h$ .

Согласно условию, сеточная функция  $y^h = u^h - v^h$  удовлетворяет неравенствам  $L^h[y^h] = L^h[u^h] - L^h[v^h] \leq 0$ ,  $y^h(x_0) = u^h(x_0) - v^h(x_0) \leq 0$ ,  $y^h(x_N) = u^h(x_N) - v^h(x_N) \leq 0$ . Поэтому в силу теоремы 15.10  $y^h \leq 0$ , что эквивалентно неравенству  $u^h \leq v^h$ .

Аналогично,  $z^h = -v^h - u^h$  удовлетворяет неравенствам  $L^h[z^h] = -L^h[v^h] - L^h[u^h] \leq 0$ ,  $z^h(x_0) = -v^h(x_0) - u^h(x_0) \leq 0$ ,  $z^h(x_N) = -v^h(x_N) - u^h(x_N) \leq 0$ . Следовательно,  $z^h \leq 0$ , что эквивалентно неравенству  $-v^h \leq u^h$ .

Итак,  $-v^h \leq u^h \leq v^h$ . ■

**6. Априорная оценка решения.** Оценим максимум модуля решения  $u^h$  разностной схемы через данные дискретной задачи (правую часть уравнения и краевые значения). Предварительно установим справедливость двух вспомогательных утверждений.

**Лемма 15.2.** Для решения разностной схемы

$$L^h[y^h] = 0, \quad x \in \omega^h, \quad (15.25)$$

$$y^h(x_0) = u_a, \quad y^h(x_N) = u_b \quad (15.26)$$

справедлива оценка

$$\max_{0 \leq i \leq N} |y_i| \leq \max \{|u_a|, |u_b|\}. \quad (15.27)$$

□ Введем сеточную функцию  $v^h \equiv M = \text{const}$ ,  $M = \max \{|u_a|, |u_b|\}$ . Заметим, что  $|L[y^h]| = 0 \leq L[v^h] = q^h M$ ,  $|y^h(x_0)| = |u_a| \leq M = v^h(x_0)$ ,  $|y^h(x_N)| = |u_b| \leq M = v^h(x_N)$ . Поэтому в силу теоремы сравнения  $|y^h| \leq v^h$ , что эквивалентно оценке (15.27). ■

**Лемма 15.3.** Для решения разностной схемы

$$L^h[z^h] = f^h, \quad x \in \omega^h, \quad (15.28)$$

$$z^h(x_0) = 0, \quad z^h(x_N) = 0 \quad (15.29)$$

справедлива оценка

$$\max_{0 \leq i \leq N} |z_i| \leq \frac{l^2}{8} \max_{0 < i < N} |f_i|. \quad (15.30)$$

□ Введем сеточную функцию  $v^h(x_i) = \frac{A}{2}(x_i - a)(b - x_i)$ , где  $A = \max_{0 < i < N} |f_i|$ . Заметим, что  $v^h \geq 0$ . Непосредственной проверкой не-

трудно убедиться в том, что  $L^h[v^h] = A + q^h v^h$ . Таким образом,

$|L^h[z^h]| = |f^h| \leq A \leq L^h[v^h]$ ,  $|z^h(x_0)| = 0 \leq v^h(x_0)$ ,  $|z^h(x_N)| = 0 \leq v^h(x_N)$  и поэтому в силу теоремы сравнения  $|z^h| \leq v^h$ . Так как максимум квадратичной функции  $\frac{A}{2}(x-a)(b-x)$  достигается при  $x = \frac{a+b}{2}$  и равен  $\frac{A}{8}l^2$ , то  $v^h \leq \frac{A}{8}l^2$  и из неравенства  $|z^h| \leq v^h$  следует оценка (15.30). ■

Сформулируем теперь основной результат этого пункта.

**Теорема 15.12.** Для решения разностной схемы (15.15), (15.16) справедлива априорная оценка

$$\max_{0 \leq i \leq N} |u_i| \leq \max\{|u_a|, |u_b|\} + \frac{l^2}{8} \max_{0 < i < N} |f_i| \quad (15.31)$$

□ Заметим, что сеточную функцию  $u^h$  можно представить в виде суммы:  $u^h = y^h + z^h$ , где  $y^h$  — решение разностной схемы (15.25), (15.26), а  $z^h$  — решение разностной схемы (15.28), (15.29). Пользуясь неравенством  $\max_{0 \leq i \leq N} |u_i| \leq \max_{0 \leq i \leq N} |y_i| + \max_{0 \leq i \leq N} |z_i|$  и оценками (15.27), (15.30), приходим к неравенству (15.31). ■

**7. Устойчивость.** Рассмотрим вопрос о чувствительности решения разностной схемы к погрешностям задания правых частей разностных уравнений. Пусть  $u^h$  — решение разностной схемы (15.15), (15.16), а  $u^{*h}$  — решение разностной схемы

$$L^h[u^{*h}] = f^{*h}, \quad x \in \omega^h, \quad (15.32)$$

$$u^{*h}(x_0) = u_a^*, \quad u^{*h}(x_N) = u_b^*, \quad (15.33)$$

где  $f^{*h} = f^h - \delta f^h$ ,  $u_a^* = u_a - \varepsilon_a$ ,  $u_b^* = u_b - \varepsilon_b$ .

Назовем разностную схему (15.15), (15.16) *устойчивой*, если при любых  $\varepsilon_a, \varepsilon_b, \delta f^h$  справедлива оценка

$$\max_{0 \leq i \leq N} |u_i - u_i^*| \leq \max\{|\varepsilon_a|, |\varepsilon_b|\} + K \max_{0 < i < N} |\delta f_i|, \quad (15.34)$$

где постоянная  $K$  не зависит от  $h$ . Отметим, что эта оценка является аналогом оценки (15.8), справедливой для краевой задачи.

**Теорема 15.13 (об устойчивости разностной схемы).** Для разностной схемы (15.15), (15.16) справедлива оценка (15.34) с постоянной  $K = \frac{l^2}{8}$ .

□ Заметим, что сеточная функция  $\varepsilon^h = u^h - u^{*h}$  является решением разностной схемы

$$L^h[\varepsilon^h] = \delta f^h, \quad x \in \omega^h, \\ \varepsilon^h(x_0) = \varepsilon_a, \quad \varepsilon^h(x_N) = \varepsilon_b.$$

Применяя для оценивания  $\varepsilon^h$  теорему 15.12, приходим к неравенству (15.34). ■

**З а м е ч а н и е.** Значение  $l^2/8$  постоянной  $K$  в неравенстве (15.34) для разностной схемы (15.15), (15.16) совпадает в силу замечания на с. 487 со значением соответствующей постоянной в неравенстве (15.8). Этот факт говорит о том, что разностная схема обладает такой же чувствительностью к ошибкам задания исходных данных, что и краевая задача.

**8. Аппроксимация.** Пусть  $u(x)$  — решение дифференциального уравнения  $L[u] = f$ . Назовем сеточную функцию  $\psi^h = L^h[u] - f^h$  *погрешностью аппроксимации разностного уравнения*

$$L^h[u^h] = f^h, \quad x \in \omega^h. \quad (15.35)$$

Из определения  $\psi^h$  следует, что справедливо равенство

$$L^h[u] = f^h + \psi^h, \quad x \in \omega^h, \quad (15.36)$$

означающее, что функция  $u$  удовлетворяет разностному уравнению (15.35) с точностью до погрешности аппроксимации.

Сеточную функцию  $\psi^h$  используют для предварительной оценки того, насколько точно аппроксимируется дифференциальное уравнение его разностным аналогом. Говорят, что *разностное уравнение (15.35) аппроксимирует дифференциальное уравнение  $L[u] = f$ , если  $\max_{0 < i < N} |\psi_i| \rightarrow 0$  при  $h \rightarrow 0$ , и аппроксимирует его с  $m$ -м порядком (при*

*$m > 0$ ), если справедлива оценка  $\max_{0 < i < N} |\psi_i| \leq Ch^m$ .*

**Л е м м а 15.4.** Пусть коэффициенты  $q$  и  $f$  дважды непрерывно дифференцируемы на отрезке  $[a, b]$ . Тогда разностное уравнение (15.15) аппроксимирует дифференциальное уравнение  $L[u] = f$  со вторым порядком, причем справедлива оценка

$$\max_{0 < i < N} |\psi_i| \leq \frac{M_4}{12} h^2, \quad M_4 = \max_{[a, b]} |u^{(4)}(x)|. \quad (15.37)$$

□ Прежде всего заметим, что в силу теоремы 15.2 функция  $u(x)$  имеет на отрезке  $[a, b]$  непрерывную производную  $u^{(4)}(x)$ .

В силу определения погрешности аппроксимации имеем

$$\begin{aligned}\psi_i &= -\frac{u(x_{i-1}) - 2u(x_i) + u(x_{i+1}))}{h^2} + q(x_i)u(x_i) - f(x_i) = \\ &= -u''(x_i) + r_h(x_i) + q(x_i)u(x_i) - f(x_i) = r_h(x_i),\end{aligned}$$

где  $r_h(x_i) = u^{(4)}(\xi_i)h^2/12$  — погрешность аппроксимации производной  $u''(x)$  ее разностным аналогом по формуле (15.11). Таким образом,

$$\max_{0 \leq i \leq N} |\psi_i| = \max_{0 \leq i \leq N} \frac{|u^{(4)}(\xi_i)|}{12} h^2 \leq \frac{M_4}{12} h^2, \text{ т. е. справедливость оценки (15.37) установлена. } \blacksquare$$

В общем случае дополнительно возникает проблема изучения погрешности аппроксимации краевых условий. Однако для краевых условий (15.10) эта проблема отсутствует, так как сеточная функция удовлетворяет им точно.

**9. Сходимость.** Пусть  $u(x)$  — решение краевой задачи, а  $u^h$  — решение соответствующей разностной схемы. Назовем *погрешностью разностной схемы* сеточную функцию  $\varepsilon^h$ , принимающую значения  $\varepsilon_i = \varepsilon^h(x_i) = u(x_i) - u^h(x_i)$  в узлах сетки  $\bar{\omega}^h$ .

Будем говорить, что *разностная схема сходится* при  $h \rightarrow 0$ , если  $\max_{0 \leq i \leq N} |\varepsilon_i| \rightarrow 0$  при  $h \rightarrow 0$ , и *сходится с  $m$ -м порядком точности* (при  $m > 0$ ), если для погрешности справедлива оценка  $\max_{0 \leq i \leq N} |\varepsilon_i| \leq Ch^m$ ,

где  $C$  некоторая постоянная, не зависящая от  $h$ .

Покажем, что разностная схема (15.15), (15.16) сходится со вторым порядком точности.

**Теорема 15.14.** Пусть функции  $q(x)$ ,  $f(x)$  дважды непрерывно дифференцируемы на отрезке  $[a, b]$ . Тогда для погрешности разностной схемы (15.15), (15.16) справедлива оценка

$$\max_{0 \leq i \leq N} |u(x_i) - u_i| \leq Ch^2, \quad (15.38)$$

$$\text{где } C = \frac{l^2}{96} \max_{[a, b]} |u^{(4)}(x)|.$$

□ Введем сеточную функцию  $u^{*h}$ , значения которой в узлах сетки совпадают с точными значениями решения краевой задачи, т. е.  $u^{*h}(x_i) = u(x_i)$ . Равенство (15.36) означает, что  $u^{*h}$  можно рассматривать как решение разностной схемы (15.32), (15.33), где  $f^{*h} = f^h + \psi^h$ ,  $u_a^* = u_a$ ,  $u_b^* = u_b$ . В силу теоремы 15.13 для  $\varepsilon^h = u^h - u^{*h}$  справедлива оценка

$$\max_{0 \leq i \leq N} |\varepsilon_i| \leq \frac{l^2}{8} \max_{0 < i < N} |\psi_i|. \quad (15.39)$$

Учитывая теперь неравенство (15.37), из (15.39) получаем оценку (15.38). ■

**З а м е ч а н и е.** Сходимость разностной схемы (15.15), (15.16) со вторым порядком точности вытекает из того, что схема устойчива и обладает аппроксимацией со вторым порядком относительно  $h$ .

**10. Оценка погрешности по правилу Рунге.** Полученная в теореме 15.14 априорная оценка (15.38), как правило, оказывается непригодной для практической оценки погрешности разностной схемы. На практике чаще применяются апостериорные оценки погрешности, использующие расчеты на сгущающихся сетках. Пусть, например,  $u^h$  и  $u^{2h}$  — решения разностной схемы (15.15), (15.16), соответствующие шагам  $h_1 = h$  и  $h_2 = 2h$ . Тогда в соответствии с *правилом Рунге* при определенных условиях справедлива приближенная формула

$$\varepsilon^h(x) = u(x) - u^h(x) \approx \frac{u^h(x) - u^{2h}(x)}{3}, \quad x \in \omega^{2h}. \quad (15.40)$$

Отметим, что она применима только в узлах сетки  $\omega^{2h}$ , т. е. там, где определены обе сеточные функции  $u^h$  и  $u^{2h}$ .

**Пример 15.1.** Используя разностную схему (15.15), (15.16) с шагом  $h = 1/8$ , найдем приближенное решение краевой задачи

$$\begin{aligned} -u''(x) + x^2 u(x) &= \left(\frac{\pi^2}{4} + x^2\right) \cos \frac{\pi}{2} x, \quad 0 < x < 1, \\ u(0) &= 1, \quad u(1) = 0 \end{aligned} \quad (15.41)$$

и оценим его погрешность по правилу Рунге. Вычисления будем вести с шестью значащими цифрами.

В данном случае  $q(x) = x^2$ ,  $f(x) = \left(\frac{\pi^2}{4} + x^2\right) \cos \frac{\pi}{2} x$  и система сеточных уравнений (15.17), (15.18) примет вид

$$\begin{aligned} u_0 &= 1, \\ -u_{i-1} + (2 + h^2 x_i^2) u_i - u_{i+1} &= \left(\frac{\pi^2}{4} + x_i^2\right) \cos \frac{\pi}{2} x_i, \quad 1 \leq i \leq N-1, \\ u_N &= 0. \end{aligned} \quad (15.42)$$

При  $h_1 = 1/8$  приходим к следующей системе уравнений относительно неизвестных  $u_i \approx u(ih)$  ( $i = 0, 1, \dots, 8$ ):

$$\begin{aligned} u_0 &= 1, \\ -u_0 + 2.00024u_1 - u_2 &= 0.0380518, \\ -u_1 + 2.00098u_2 - u_3 &= 0.0365207, \\ -u_2 + 2.00220u_3 - u_4 &= 0.0338827, \\ -u_3 + 2.00391u_4 - u_5 &= 0.0300233, \\ -u_4 + 2.00610u_5 - u_6 &= 0.0248099, \\ -u_5 + 2.00897u_6 - u_7 &= 0.0181171, \\ -u_6 + 2.01196u_7 - u_8 &= 0.0098552, \\ u_8 &= 0. \end{aligned}$$

Решая ее с помощью метода прогонки, находим значения, представленные в 3-м столбце табл. 15.1. Заметим, что в данном случае точное решение задачи известно:  $u(x) = \cos \frac{\pi}{2} x$ . Значения точного решения и вычисленные с их использованием погрешности приведены во 2-м и 4-м столбцах той же таблицы.

Т а б л и ц а 15.1

$x_i$	$u = \cos \frac{\pi}{2} x$	$u^{h_1};$ $h_1 = 1/8$	$\varepsilon^{h_1};$ $h_1 = 1/8$	$u^{h_2};$ $h_2 = 1/4$	Оценка погрешности по правилу Рунге
0.000	1.000000	1.000000	0	1.000000	0
0.125	0.980785	0.981114	$-3 \cdot 10^{-4}$	-	-
0.250	0.923880	0.924413	$-5 \cdot 10^{-4}$	0.926080	$-6 \cdot 10^{-4}$
0.375	0.831470	0.832097	$-6 \cdot 10^{-4}$	-	-
0.500	0.707107	0.707733	$-6 \cdot 10^{-4}$	0.709703	$-7 \cdot 10^{-4}$
0.625	0.555570	0.556116	$-5 \cdot 10^{-4}$	-	-
0.750	0.382683	0.383082	$-4 \cdot 10^{-4}$	0.384324	$-4 \cdot 10^{-4}$
0.875	0.195090	0.195300	$-2 \cdot 10^{-4}$	-	-
1.000	0.000000	0.000000	0	0.000000	0

Оценим теперь погрешность, используя правило Рунге. Возьмем шаг  $h_2 = 2h_1 = 1/4$ . Решая соответствующую систему сеточных уравнений:

$$\begin{aligned} u_0 &= 1, \\ -u_0 + 2.00391u_1 - u_2 &= 0.146083, \\ -u_1 + 2.01563u_2 - u_3 &= 0.120093, \\ -u_2 + 2.03516u_3 - u_4 &= 0.0724683, \\ u_4 &= 0, \end{aligned}$$

получаем значения, представленные в 5-м столбце табл. 15.1. В последнем столбце этой таблицы даны приближенные значения погрешности, полученные по формуле (15.40). Заметим, что в данном примере правило Рунге дает весьма хорошие результаты.

**11. Влияние вычислительной погрешности.** При расчетах с достаточно крупными шагами  $h$  влиянием вычислительной погрешности на решение часто можно пренебречь. Однако все же следует иметь в виду, что при решении системы (15.17), (15.18) методом прогонки происходит накопление вычислительной погрешности. Известно<sup>1</sup>, что при  $h \rightarrow 0$  вычислительная погрешность может возрасти здесь пропорционально  $\epsilon_m/h^2$ , где  $\epsilon_m$  — относительная точность представления чисел в ЭВМ. Таким образом, при достаточно малых значениях шага  $h$  возможна катастрофическая потеря точности.

Сделанное выше утверждение перестанет казаться неправдоподобным, если мы убедимся в том, что при малых  $h$  вычислительная погрешность может привести к существенному искажению решения уже на этапе составления системы сеточных уравнений. Пусть, например, для решения краевой задачи (15.9), (15.10) используется разностная схема с шагом  $h = 10^{-3}$ , а вычисления ведутся на 6-разрядной десятичной ЭВМ. Заметим, что для такой ЭВМ  $\epsilon_m = 5 \cdot 10^{-7}$ . Так как здесь  $h^2 x_i^2 < 10^{-6} = 2\epsilon_m$ , то результатом вычисления коэффициента  $b_i = 2 + h^2 x_i^2$  после округления до 6 значащих цифр мантииссы является число  $b_i^* = 2$ . Следовательно, даже если остальные вычисления будут производиться точно, то фактически окажется найденным не решение системы (15.42), а решение системы

$$u_0^* = 1,$$

$$-u_{i-1}^* + 2u_i^* - u_{i+1}^* = h^2 \left( \frac{\pi^2}{4} + x_i^2 \right) \cos \frac{\pi}{2} x_i, \quad 1 \leq i \leq N-1,$$

$$u_N = 0,$$

соответствующей краевой задаче

$$-u''(x) = \left( \frac{\pi^2}{4} + x^2 \right) \cos \frac{\pi}{2} x,$$

$$u(0) = 1, \quad u(1) = 0.$$

---

<sup>1</sup> Бахвалов Н.С. О накоплении вычислительной погрешности при численном решении дифференциальных уравнений. В сб.: Вычислительные методы и программирование. М.: Изд-во МГУ, 1962, с. 47–68.



Поскольку в результате оказалась решенной "не та задача", найденные значения  $u_i^*$  будут существенно отличаться от искомых  $u_i$ . В данном конкретном случае погрешность будет достигать  $\approx 5\%$ . В общем случае погрешность может оказаться значительно больше.

### § 15.3. Метод конечных разностей: аппроксимации специального вида

1. **Случай переменного коэффициента  $k(x)$ .** Вернемся к проблеме численного решения краевой задачи

$$-(k(x) u'(x))' + q(x) u(x) = f(x), \quad a < x < b; \quad (15.43)$$

$$u(a) = u_a, \quad u(b) = u_b. \quad (15.44)$$

По сравнению со случаем  $k \equiv 1$ , рассмотренным в предыдущем параграфе, единственное видимое отличие состоит в необходимости выбора подходящей аппроксимации для выражения<sup>1</sup>  $-(k(x) u'(x))' = w'(x)$ . Рассмотрим некоторые из возможных подходов к выбору аппроксимации.

Введем обозначения  $x_{i+1/2} = (x_i + x_{i+1})/2$ ,  $k_{i+1/2} = k(x_{i+1/2})$ ,  $0 \leq i \leq N$ . Аппроксимируем производную  $w'(x)$  при  $x = x_i$  следующим образом:

$$w'(x_i) \approx \frac{1}{h} (w(x_{i+1/2}) - w(x_{i-1/2})). \quad (15.45)$$

Используя далее приближенные формулы

$$w(x_{i+1/2}) = k_{i+1/2} u'(x_{i+1/2}) \approx k_{i+1/2} \frac{u(x_{i+1}) - u(x_i)}{h}, \quad (15.46)$$

$$w(x_{i-1/2}) = k_{i-1/2} u'(x_{i-1/2}) \approx k_{i-1/2} \frac{u(x_i) - u(x_{i-1})}{h}, \quad (15.47)$$

получаем аппроксимацию

$$-(ku')' \Big|_{x=x_i} \approx -\frac{1}{h} \left[ k_{i+1/2} \frac{u(x_{i+1}) - u(x_i)}{h} - k_{i-1/2} \frac{u(x_i) - u(x_{i-1})}{h} \right].$$

В результате приходим к разностной схеме вида (15.15), (15.16), где

<sup>1</sup> Напомним, что величина  $w(x) = -k(x) u'(x)$  имеет физический смысл потока тепла, если уравнение интерпретируется как уравнение теплопроводности.

$$L^h[u^h](x_i) = -\frac{1}{h} \left[ k_{i+1/2} \frac{u_{i+1} - u_i}{h} - k_{i-1/2} \frac{u_i - u_{i-1}}{h} \right] + q_i u_i. \quad (15.48)$$

Отметим, что коэффициенты  $a_i = -k_{i-1/2}$ ,  $b_i = k_{i-1/2} + k_{i+1/2} + h^2 q_i$ ,  $c_i = -k_{i+1/2}$  соответствующей системы сеточных уравнений удовлетворяют условиям (15.23). Следовательно, при любом  $h$  решение разностной схемы существует и единственно. Кроме того, в силу леммы 15.1 для разностной схемы справедлив принцип максимума. Можно показать также, что разностная схема устойчива и сходится со вторым порядком точности, если коэффициенты  $k$ ,  $q$ ,  $f$  являются дважды непрерывно дифференцируемыми на отрезке  $[a, b]$  функциями.

Формальный подход к выбору аппроксимации дифференциального уравнения может давать разностные схемы, обладающие теми или иными дефектами. Например, кажется удобным предварительно преобразовать первое слагаемое уравнение (15.43) следующим образом:  $(ku')' = ku'' + k'u'$ . После такого преобразования для этого слагаемого естествен выбор аппроксимации

$$(ku')' \Big|_{x=x_i} \approx k(x_i) \frac{u(x_{i-1}) - 2u(x_i) + u(x_{i+1}))}{h^2} + k'(x_i) \frac{u(x_{i+1}) - u(x_{i-1}))}{2h},$$

приводящей к разностной схеме с оператором

$$L^h[u^h](x_i) = -k(x_i) \frac{u_{i-1} - 2u_i + u_{i+1}}{h^2} - k'(x_i) \frac{u_{i+1} - u_{i-1}}{2h} + q_i u_i.$$

Заметим, что коэффициенты соответствующей системы сеточных уравнений

$$a_i = -k(x_i) + \frac{h}{2} k'(x_i), \quad b_i = 2k(x_i) + h^2 q_i, \quad c_i = -k(x_i) - \frac{h}{2} k'(x_i)$$

удовлетворяют условиям (15.23), гарантирующим наличие принципа максимума, только если

$$h \max_{1 \leq i \leq N} \frac{|k'(x_i)|}{k(x_i)} < 2. \quad (15.49)$$

Таким образом, в случае, когда коэффициент  $k$  может резко меняться на отрезке  $[a, b]$ , ограничение (15.49) приводит к необходимости выбора очень мелкого шага  $h$  для получения приемлемых результатов.

**2. Случай неравномерной сетки.** Часто возникает необходимость использования *неравномерной сетки*  $\bar{\omega}^h$ , т. е. сетки, у которой шаг  $h_i =$

$= x_i - x_{i-1}$  зависит от  $i$ . Положим  $h_{i+1/2} = x_{i+1/2} - x_{i-1/2}$ . Заменяя в формулах (15.45), (15.46), (15.47)  $h$  на  $h_{i+1/2}$ ,  $h_{i+1}$ ,  $h_i$  соответственно, придем к разностной схеме (15.15), (15.16), в которой

$$L^h[u^h](x_i) = -\frac{1}{h_{i+1/2}} \left[ k_{i+1/2} \frac{u_{i+1} - u_i}{h_{i+1}} - k_{i-1/2} \frac{u_i - u_{i-1}}{h_i} \right] + q_i u_i.$$

Нетрудно убедиться в том, что при такой аппроксимации справедлив принцип максимума и разностная схема устойчива. Можно показать, что при некоторых дополнительных предположениях она сходится со вторым порядком точности относительно  $h_{\max}$ .

**3. Разности "против потока".** Как отмечалось выше, уравнение (15.43) описывает установившееся распределение температуры в неподвижной среде. В том случае, когда исследуются тепловые процессы в движущейся среде (например, рассматривается поток жидкости), уравнение модифицируется следующим образом:

$$-(k(x)u'(x))' + v(x)u'(x) + q(x)u(x) = f(x).$$

Здесь  $v(x)$  — величина, пропорциональная скорости потока жидкости.

При дискретизации этого уравнения возникает новый момент, связанный с необходимостью аппроксимации слагаемого  $v(x)u'(x)$ . Кажется естественным воспользоваться для аппроксимации производной  $u'$  центральной разностной производной. В результате к разностному оператору (15.48) добавится слагаемое  $v_i \frac{u_{i+1} - u_{i-1}}{2h}$ , где  $v_i = v(x_i)$ .

Выясним, удовлетворяют ли коэффициенты

$$a_i = -k_{i-1/2} - \frac{h}{2} v_i, \quad b_i = k_{i-1/2} + k_{i+1/2} + h^2 q_i, \quad c_i = -k_{i+1/2} + \frac{h}{2} v_i$$

соответствующей системы сеточных уравнений условиям (15.23), гарантирующим выполнение принципа максимума. Как нетрудно видеть, неравенства (15.23) выполняются, если  $h|v_i| < 2 \min \{k_{i-1/2}, k_{i+1/2}\}$ .

В том случае, когда скорость потока велика, это неравенство приводит к весьма жесткому ограничению на шаг  $h$ . Его можно избежать, если использовать односторонние разностные производные. В задачах динамики жидкостей и газов широко используются аппроксимации вида

$$v(x_i)u'(x_i) \approx v_i^+ \frac{u(x_i) - u(x_{i-1}))}{h} + v_i^- \frac{u(x_{i+1}) - u(x_i)}{h}, \quad (15.50)$$

где  $v_i^- = \min \{v(x_i), 0\}$ ,  $v_i^+ = \max \{v(x_i), 0\}$ . Они называются *аппрок-*

смацациями "против потока" (или "против ветра"). Такой выбор аппроксимации слагаемого  $vu'$  приводит к системе сеточных уравнений с коэффициентами

$$a_i = -(k_{i-1/2} + hv_i^+), \quad b_i = k_{i-1/2} + k_{i+1/2} + hv_i + h^2 q_i, \quad c_i = -(k_{i+1/2} - hv_i^-).$$

Легко убедиться в том, что условия (15.23) здесь всегда выполняются. Таким образом, принцип максимума выполняется при любых шагах  $h$ . Правда, при использовании приближения (15.50) порядок аппроксимации снижается со второго до первого.

**4. Случай разрывных коэффициентов.** Одна из специфических особенностей, присущих многим техническим задачам, заключается в том, что среда, в которой изучаются те или иные процессы, как правило, существенно неоднородна и состоит из материалов с разными физическими свойствами. При математической формулировке таких задач эта особенность проявляется в том, что коэффициенты дифференциальных уравнений становятся разрывными. Это существенно усложняет построение эффективных численных методов.

Предположим, например, что коэффициенты  $k$ ,  $q$ ,  $f$ , входящие в уравнение (15.43), могут иметь на отрезке  $[a, b]$  конечное число  $M$  точек разрыва  $\xi_i$  ( $a < \xi_1 < \xi_2 < \dots < \xi_M < b$ ) первого рода. Будем предполагать, что всюду за исключением этих точек коэффициенты  $k$ ,  $q$ ,  $f$  непрерывны и удовлетворяют условиям  $k(x) \geq k_0 > 0$ ,  $q(x) \geq 0$ .

В этом случае решение краевой задачи (15.43), (15.44) уже нельзя понимать в классическом смысле. Уточним постановку задачи для уравнения с разрывными коэффициентами. Назовем функцию  $u(x)$  решением задачи (15.43), (15.44), если:

- 1) функция  $u(x)$  непрерывна на отрезке  $[a, b]$  и удовлетворяет крайевым условиям  $u(a) = u_a$ ,  $u(b) = u_b$ ;
- 2) поток  $w(x) = -k(x)u'(x)$  непрерывен на отрезке  $[a, b]$ ;
- 3) всюду за исключением точек  $\xi_1, \xi_2, \dots, \xi_M$  функция  $w(x)$  непрерывно дифференцируема и удовлетворяет уравнению

$$w'(x) + q(x)u(x) = f(x). \quad (15.51)$$

Для вывода разностных уравнений воспользуемся методом баланса<sup>1</sup>. Запишем уравнение теплового баланса для отрезка  $[x_{i-1/2}, x_{i+1/2}]$ , где  $1 \leq i \leq N-1$ . Для этого проинтегрируем уравнение (15.51) по  $x$  от  $x_{i-1/2}$  до  $x_{i+1/2}$ . В результате получим равенство

<sup>1</sup> Иногда метод баланса называют *интегро-интерполяционным методом* [70].

$$w(x_{i+1/2}) - w(x_{i-1/2}) + \int_{x_{i-1/2}}^{x_{i+1/2}} q u dx = \int_{x_{i-1/2}}^{x_{i+1/2}} f dx. \quad (15.52)$$

Воспользовавшись приближенной формулой  $\int_{x_{i-1/2}}^{x_{i+1/2}} q u dx \approx u(x_i) \int_{x_{i-1/2}}^{x_{i+1/2}} q dx$  и разделив обе части равенства (15.52) на  $h_{i+1/2}$ , получим

$$\frac{1}{h_{i+1/2}} (w(x_{i+1/2}) - w(x_{i-1/2})) + q_i^h u(x_i) \approx f_i^h. \quad (15.53)$$

Здесь  $q_i^h = \frac{1}{h_{i+1/2}} \int_{x_{i-1/2}}^{x_{i+1/2}} q(x) dx$ ,  $f_i^h = \frac{1}{h_{i+1/2}} \int_{x_{i-1/2}}^{x_{i+1/2}} f(x) dx$  — средние значения функций  $q$  и  $f$  на отрезке  $[x_{i-1/2}, x_{i+1/2}]$ .

Далее заметим, что

$$u(x_{i+1}) - u(x_i) = \int_{x_i}^{x_{i+1}} u'(x) dx = - \int_{x_i}^{x_{i+1}} \frac{w(x)}{k(x)} dx \approx -w(x_{i+1/2}) \int_{x_i}^{x_{i+1}} \frac{dx}{k(x)}.$$

Таким образом,

$$w(x_{i+1/2}) \approx -k_{i+1/2}^h \frac{u(x_{i+1}) - u(x_i)}{h_{i+1}}, \quad (15.54)$$

где  $k_{i+1/2}^h = \left[ \frac{1}{h_{i+1}} \int_{x_i}^{x_{i+1}} \frac{dx}{k(x)} \right]^{-1}$  — эффективное значение коэффициента теплопроводности на отрезке  $[x_i, x_{i+1}]$ . Заметим (это важно!), что усредняется фактически не коэффициент теплопроводности  $k(x)$ , а обратный к нему коэффициент теплового сопротивления  $(k(x))^{-1}$ .

Перейдем теперь от приближенных равенств (15.53), (15.54) к разностному уравнению

$$-\frac{1}{h_{i+1/2}} \left[ k_{i+1/2}^h \frac{u_{i+1} - u_i}{h_{i+1}} - k_{i-1/2}^h \frac{u_i - u_{i-1}}{h_i} \right] + q_i^h u_i = f_i^h, \quad 1 \leq i \leq N-1. \quad (15.55)$$

Добавляя к (15.55) уравнения

$$u_0 = u_a, \quad u_N = u_b, \quad (15.56)$$

приходим к разностной схеме (15.55), (15.56).

**З а м е ч а н и е.** Разностные уравнения (15.55) записываются единообразно во всех внутренних узлах сетки независимо от того,

где расположены точки разрыва коэффициентов дифференциального уравнения. Это означает, что рассматриваемая разностная схема относится к классу *однородных разностных схем* [70].

**5. Аппроксимация краевых условий.** Выше при аппроксимации краевой задачи краевые условия первого рода  $u(a) = u_a$ ,  $u(b) = u_b$  не вызывали каких-либо затруднений и потому основное внимание уделялось аппроксимации дифференциального оператора. Однако краевые условия могут иметь более сложный вид и тогда возникает проблема их аппроксимации.

Рассмотрим, например, краевое условие второго рода

$$-k(a)u'(a) = w_a. \quad (15.57)$$

Простейший подход к его аппроксимации состоит в замене производной  $u'(a)$  разностным отношением  $\frac{u(a+h) - u(a)}{h}$ . В результате получается разностное краевое условие

$$-k(a) \frac{u_1 - u_0}{h} = w_a. \quad (15.58)$$

Так как

$$\frac{u(a+h) - u(a)}{h} = u'(a) + \frac{u''(a)}{2} h + \frac{u^{(3)}(a)}{6} h^2 + \dots,$$

то разностное уравнение (15.58) аппроксимирует краевое условие (15.57) лишь с первым порядком относительно  $h$ , что приводит к понижению порядка точности разностной схемы. Порядок аппроксимации краевого условия можно повысить разными способами. Например, можно заметить, что в силу дифференциального уравнения (15.43) при  $x = a$  для решения  $u$  справедливо равенство

$$k(a)u''(a) = -k'(a)u'(a) + q(a)u(a) - f(a).$$

Таким образом,

$$\begin{aligned} -k(a) \frac{u(a+h) - u(a)}{h} &= w_a + \frac{h}{2} \left[ -\frac{k'(a)}{k(a)} w_a - q(a)u(a) + f(a) \right] - \\ &- k(a) \frac{u^{(3)}(a)}{6} h^2 + \dots, \end{aligned}$$

и мы приходим к разностному краевому условию

$$-k(a) \frac{u_1 - u_0}{h} + \frac{h}{2} q(a) u_0 = \left[ 1 - \frac{h}{2} \frac{k'(a)}{k(a)} \right] w_a + \frac{h}{2} f(a),$$

аппроксимирующему краевое условие (15.57) со вторым порядком.

Другая аппроксимация второго порядка относительно  $h$  получится, если использовать метод баланса. Проинтегрируем уравнение (15.51) по  $x$  от  $x_0$  до  $x_{1/2} = x_0 + h/2$ . В результате, учитывая, что  $w(x_0) = w_a$ ,

получим равенство  $w(x_{1/2}) - w_a + \int_{x_0}^{x_{1/2}} q u dx = \int_{x_0}^{x_{1/2}} f dx$ . Отсюда, используя приближенное равенство (15.54), приходим к разностному уравнению

$$-k_{1/2}^h \frac{u_1 - u_0}{h} + \frac{h}{2} q_0^h u_0 = w_a + \frac{h}{2} f_0^h,$$

где

$$q_0^h = \frac{2}{h} \int_{x_0}^{x_{1/2}} q dx, \quad f_0^h = \frac{2}{h} \int_{x_0}^{x_{1/2}} f dx.$$

#### § 15.4. Понятие о проекционных и проекционно-разностных методах.

Методы Рунге и Галеркина.

Метод конечных элементов

Наряду с методом конечных разностей значительной популярностью пользуются проекционные методы Рунге и Галеркина, а точнее — их современные варианты, объединяемые названием "метод конечных элементов" или "проекционно-сеточные методы".

**1. Вариационная постановка краевой задачи.** Вариационные методы, представляющие собой частный случай проекционных методов, используются для решения самых разнообразных задач на протяжении многих десятков лет. Эти методы применяются для решения тех задач физики и техники, которые могут быть описаны с помощью так называемых *вариационных принципов*. В соответствии с одним из простейших вариационных принципов функция  $u(x)$ , являющаяся решением задачи, должна быть стационарной точкой *вариационного функционала*

$$J(u) = \int_a^b F(x, u, u') dx. \quad (15.59)$$

Вариационный функционал, как правило, имеет определенный физический смысл. Нередко он выражает потенциальную энергию физической системы.

Обозначим через  $U$  множество функций, на котором определен функционал  $J(u)$ . Будем считать, что входящие в  $U$  функции удовлетворяют условиям

$$u(a) = u_a, \quad u(b) = u_b, \quad (15.60)$$

где значения  $u_a$  и  $u_b$  фиксированы. Предположим также, что в множество  $U$  входят все непрерывные кусочно-гладкие функции, принимающие на концах отрезка  $[a, b]$  значения (15.60).

Предположим, что дважды непрерывно дифференцируемая функция  $u(x)$  является стационарной точкой функционала (15.59). Тогда, как известно из курса вариационного исчисления [93], эта функция должна удовлетворять дифференциальному уравнению

$$-\frac{d}{dx} F'_u(x, u, u') + F''_u(x, u, u') = 0, \quad (15.61)$$

которое принято называть *уравнением Эйлера* (или *уравнением Эйлера — Лагранжа*). Таким образом, решение вариационной задачи оказывается решением краевой задачи (15.61), (15.60). Более того, при некоторых условиях эти задачи оказываются эквивалентными и возникает возможность решать определенный класс краевых задач, используя методы вариационного исчисления.

Рассмотрим теперь функционал

$$J(u) = \frac{1}{2} \int_a^b (k(u')^2 + qu^2) dx - \int_a^b fu dx, \quad (15.62)$$

где  $k(x)$ ,  $q(x)$ ,  $f(x)$  — кусочно-непрерывные функции, удовлетворяющие условиям  $k(x) \geq k_0 > 0$ ,  $q(x) \geq 0$ . Поставим вариационную задачу о поиске точки минимума функционала (15.62) на множестве  $U$ . Как нетрудно видеть, в рассматриваемом случае

$$F(x, u, u') = \frac{1}{2} (k(x)(u')^2 + q(x)u^2) - f(x)u$$

и уравнение Эйлера принимает следующий вид:

$$-(ku')' + qu = f. \quad (15.63)$$

Можно доказать, что функция  $u$  является точкой минимума функционала (15.62), т. е. удовлетворяет условию



$$J(u) = \min_{v \in U} J(v), \quad (15.64)$$

тогда и только тогда, когда она является решением краевой задачи (15.63), (15.60).

Отметим одно достоинство вариационной постановки задачи (15.63), (15.60). Она исключает необходимость требования наличия у рассматриваемых функций второй производной и даже непрерывности первой производной. Это обстоятельство оказывается весьма ценным для многих приближенных методов.

**2. Метод Ритца.** Рассмотрим приближенный метод решения вариационной задачи о поиске точки минимума функционала  $J(u)$  на множестве  $U$ . Будем искать приближенное решение  $u^N$  в виде следующей линейной комбинации:

$$u^N(x) = \sum_{j=0}^N \alpha_j \varphi_j(x). \quad (15.65)$$

Здесь  $\varphi_0(x), \varphi_1(x), \dots, \varphi_N(x)$  — некоторые фиксированные функции, которые далее мы будем называть *базисными*. Предполагается, что система базисных функций линейно независима и линейными комбинациями (15.65) при соответствующем выборе коэффициентов  $\alpha_0, \alpha_1, \dots, \alpha_N$  можно аппроксимировать решение  $u$  с желаемой степенью точности.

Обозначим через  $U^N$  множество всех функций вида (15.65) (при фиксированных  $\varphi_0, \varphi_1, \dots, \varphi_N$ ), удовлетворяющих условиям  $u^N(a) = u_a, u^N(b) = u_b$ . Предположим далее, что базисные функции удовлетворяют следующим условиям:  $\varphi_0(a) = 1, \varphi_j(a) = 0$  для всех  $j \geq 1$ ;  $\varphi_N(b) = 1, \varphi_j(b) = 0$  для всех  $j \leq N - 1$ . Тогда, как нетрудно видеть, условия (15.60) для  $u = u^N$  выполняются тогда и только тогда, когда справедливы равенства

$$\alpha_0 = u_a, \alpha_N = u_b. \quad (15.66)$$

Согласно методу Ритца<sup>1</sup>, приближенное решение  $u^N$  определяется как функция, минимизирующая функционал  $J$  на множестве  $U^N$ . Таким образом, по определению

$$J(u^N) = \min_{v \in U^N} J(v). \quad (15.67)$$

Заметим, что задача (15.67) представляет собой задачу минимизации

---

<sup>1</sup> Вальтер Ритц (1878—1909) — швейцарский физик и математик.

ции функции многих переменных. В самом деле, величина  $J(v) = J(\sum_{j=0}^N \alpha_j \varphi_j)$  является функцией  $N - 1$  переменных  $\alpha_1, \alpha_2, \dots, \alpha_{N-1}$  (значения  $\alpha_0 = u_a, \alpha_N = u_b$  фиксированы). Согласно необходимому условию экстремума, минимум этой функции достигается при тех значениях параметров  $\alpha_1, \alpha_2, \dots, \alpha_{N-1}$ , для которых выполняются равенства

$$\frac{\partial}{\partial \alpha_i} J(\sum_{j=0}^N \alpha_j \varphi_j) = 0, \quad i = 1, 2, \dots, N-1. \quad (15.68)$$

Добавляя к этим равенствам условия (15.66), приходим к системе уравнений (15.68), (15.66), из которых можно определить значения коэффициентов  $\alpha_j$  ( $j = 0, 1, \dots, N$ ) и тем самым — приближение  $u^N$ .

Применим метод Ритца к решению краевой задачи для уравнения (15.63) с краевыми условиями первого рода. Для функционала (15.62) имеем

$$\begin{aligned} J(\sum_{j=0}^N \alpha_j \varphi_j) &= \frac{1}{2} \int_a^b [k (\sum_{j=0}^N \alpha_j \varphi_j')^2 + q (\sum_{j=0}^N \alpha_j \varphi_j)^2] dx - \int_a^b f \sum_{j=0}^N \alpha_j \varphi_j dx; \\ \frac{\partial}{\partial \alpha_i} J(\sum_{j=0}^N \alpha_j \varphi_j) &= \int_a^b [k (\sum_{j=0}^N \alpha_j \varphi_j') \varphi_i' + q (\sum_{j=0}^N \alpha_j \varphi_j) \varphi_i] dx - \int_a^b f \varphi_i dx = \\ &= \sum_{j=0}^N \int_a^b (k \varphi_i' \varphi_j' + q \varphi_i \varphi_j) dx \alpha_j - \int_a^b f \varphi_i dx. \end{aligned}$$

Система (15.68), (15.66) в данном случае превращается в систему линейных алгебраических уравнений

$$\sum_{j=0}^N a_{ij} \alpha_j = b_i, \quad i = 1, 2, \dots, N-1, \quad (15.69)$$

$$\alpha_0 = u_a, \quad \alpha_N = u_b, \quad (15.70)$$

где  $a_{ij} = \int_a^b (k \varphi_i' \varphi_j' + q \varphi_i \varphi_j) dx$ ,  $b_i = \int_a^b f \varphi_i dx$ .

Исключая переменные  $\alpha_0$  и  $\alpha_N$ , систему (15.69), (15.70) можно свести к эквивалентной системе уравнений

$$A\alpha = d.$$

Здесь  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_{N-1})^T$ ,  $A$  — матрица порядка  $N - 1$  с элементами

$a_{ij}$  ( $i, j = 1, 2, \dots, N-1$ ),  $\mathbf{d} = (d_1, d_2, \dots, d_{N-1})^T$ , где  $d_i = b_i - a_{i0}u_a - a_{iN}u_b$ ,  $i = 1, 2, \dots, N-1$ .

Отметим, что матрица  $A$  — симметричная и положительно определенная.

### 3. Проекционная постановка краевой задачи. Краевая задача

$$L[u] = f, \quad x \in [a, b], \quad (15.71)$$

$$u(a) = u_a, \quad u(b) = u_b \quad (15.72)$$

допускает вариационную постановку тогда и только тогда, когда дифференциальное уравнение (15.71) является уравнением Эйлера для некоторого функционала  $J$ . Таким образом, этим свойством обладают далеко не все задачи. Например, краевая задача для уравнения

$$-(ku')' + vu' + qu = f \quad (15.73)$$

при  $v(x) \neq 0$  не допускает классической вариационной постановки.

Приведем проекционную постановку краевой задачи, которая имеет место и в том случае, когда задача не может быть сформулирована как вариационная.

Будем называть *пробной функцией* всякую непрерывную на отрезке  $[a, b]$  кусочно-дифференцируемую функцию  $\varphi(x)$ , обращающуюся в нуль при  $x = a$ ,  $x = b$ . Множество всех пробных функций обозначим через  $\Phi$ . Умножив уравнение (15.71) на произвольную функцию  $\varphi \in \Phi$  и проинтегрировав полученное равенство по  $x$  от  $a$  до  $b$ , получим *интегральное тождество*<sup>1</sup>

$$\int_a^b L[u] \varphi \, dx = \int_a^b f \varphi \, dx. \quad (15.74)$$

Итак, если функция  $u$  является решением дифференциального уравнения (15.71), то она должна удовлетворять интегральному тождеству (15.74). В то же время, как следует из основной леммы вариационного исчисления [93], если интегральное тождество (15.74) выполняется для любой пробной функции  $\varphi$ , то  $L[u] = f$ .

Таким образом, краевую задачу (15.71), (15.72) можно сформулировать в следующей проекционной постановке. Требуется найти такую функцию  $u$ , которая удовлетворяет интегральному тождеству (15.74)

---

<sup>1</sup> Равенство (15.74) называют интегральным тождеством, подчеркивая тем самым, что оно выполняется для любой пробной функции  $\varphi$ .

для произвольной пробной функции  $\varphi \in \Phi$  и для которой выполнены краевые условия (15.72).

Приведем в качестве примера интегральное тождество

$$\int_a^b (-(ku')' + vu' + qu) \varphi \, dx = \int_a^b f \varphi \, dx, \quad (15.75)$$

соответствующее дифференциальному уравнению (15.73). Придадим тождеству (15.75) несколько иную форму. Для этого преобразуем сла-

гаемое  $-\int_a^b (ku')' \varphi \, dx$ . Используя формулу интегрирования по частям, с учетом равенств  $\varphi(a) = 0$ ,  $\varphi(b) = 0$  получим

$$-\int_a^b (ku')' \varphi \, dx = -ku' \varphi \Big|_a^b + \int_a^b ku' \varphi' \, dx = \int_a^b ku' \varphi' \, dx.$$

В результате интегральное тождество примет вид

$$\int_a^b (ku' \varphi' + vu' \varphi + qu \varphi) \, dx = \int_a^b f \varphi \, dx. \quad (15.76)$$

Отметим, что при замене уравнения (15.73) интегральным тождеством (15.76) отпадает необходимость рассматривать только лишь функции  $u(x)$ , обладающие вторыми производными. Это обстоятельство играет важную роль при построении и исследовании методов решения рассматриваемой задачи, а также ряда других задач. Кроме того, проекционная постановка оказывается удобной при рассмотрении уравнений с разрывными коэффициентами.

**5. Метод Галеркина.** Как и в методе Ритца, в *методе Галеркина*<sup>1</sup> приближенное решение ищется в виде

$$u^N(x) = \sum_{j=0}^N \alpha_j \varphi_j(x).$$

Однако в отличие от метода Ритца основой для построения метода является не вариационная, а более общая проекционная постановка задачи. За приближенное решение в методе Галеркина принимается функция  $u^N \in U^N$ , которая удовлетворяет интегральному тождеству

<sup>1</sup> Борис Григорьевич Галеркин (1871—1945) русский инженер, ученый, специалист в области строительной механики и теории упругости.

$$\int_a^b L[u^M] \varphi \, dx = \int_a^b f \varphi \, dx$$

для любой пробной функции  $\varphi = \varphi_i$ ,  $i = 1, 2, \dots, N-1$ .

Для задачи (15.71), (15.72) метод Галеркина с использованием интегрального тождества (15.76) приводит к следующей системе уравнений:

$$\begin{aligned} & \int_a^b \left[ k \left( \sum_{j=0}^N \alpha_j \varphi_j' \right) \varphi_i' + v \left( \sum_{j=0}^N \alpha_j \varphi_j' \right) \varphi_i + q \left( \sum_{j=0}^N \alpha_j \varphi_j \right) \varphi_i \right] dx = \\ & = \int_a^b f \varphi_i \, dx \quad (i = 1, 2, \dots, N-1), \\ & \alpha_0 = u_a, \quad \alpha_N = u_b. \end{aligned}$$

Заметим, что эта система при  $v(x) \equiv 0$  в точности совпадает с системой (15.69), (15.70), полученной методом Ритца. Таким образом, применительно к решению краевой задачи (15.63), (15.60) методы Ритца и Галеркина оказываются эквивалентными.

**З а м е ч а н и е.** Приближенное решение  $u^h$ , определяемое методом конечных разностей, задается только в узлах сетки  $\bar{\omega}^h$ . Поэтому для получения значения решения в произвольной точке приходится производить интерполяцию. В то же время проекционные методы дают в качестве приближенного решения функцию (15.65), вычисляемую в произвольной точке  $x$ .

Как мы отмечали в предыдущих параграфах, системы сеточных уравнений, получаемые методом конечных разностей, обладают тем важным свойством, что матрицы коэффициентов этих систем являются разреженными (более того, в рассмотренных примерах матрицы были трехдиагональными). Для решения таких систем разработаны эффективные методы.

В общем случае применение методов Ритца и Галеркина к решению краевых задач приводит к необходимости вычислять решения систем уравнений вида  $A\alpha = d$  с заполненными (и зачастую плохо обусловленными) матрицами  $A$ . Современные варианты проекционных методов, объединяемые термином "метод конечных элементов", свободны от указанного недостатка. Перейдем к их рассмотрению.

**6. Метод конечных элементов.** Метод конечных элементов представляет собой разновидность проекционных методов, основанную на специальном выборе базисных функций.

История метода весьма поучительна. Метод конечных элементов впервые был предложен Р. Курантом<sup>1</sup> в 1943 г., но тогда его важная работа опередила потребности практики и фактически осталась незамеченной. Затем в начале 50-х годов инженерами — специалистами по строительной механике был разработан новый подход к решению задач теории упругости. В тех случаях, когда расчетная область имела сложную геометрию, она разбивалась на подобласти простой геометрии, в каждой из которых решение могло быть найдено аналитически. Эти подобласти были названы конечными элементами, а сам подход — методом конечных элементов. Только в начале 60-х годов математиками были осознаны практическое значение и математическая природа метода. В 60 и 70-х годах шло бурное развитие теории метода, он завоевывал все более широкие области применения. К настоящему времени метод конечных элементов получил самое широкое распространение в вычислительной практике. На его основе разработано большое число пакетов прикладных программ для решения разнообразных инженерных и научных задач.

Отметим характерные черты метода конечных элементов, выделяющие его среди других проекционных методов.

1) Расчетная область (множество изменения независимой переменной) разбивается на конечное число элементарных подмножеств стандартной формы (которые и называют *конечными элементами*).

2) Используемые базисные функции  $\varphi_j$  таковы, что они: на каждом элементе имеют простой вид (чаще всего — многочлены); отличны от нуля лишь на нескольких соседних элементах.

Покажем, как применяется метод конечных элементов к решению краевой задачи (15.63), (15.60). Разобьем отрезок  $[a, b]$  точками  $a = x_0 < x_1 < \dots < x_N = b$  на  $N$  элементарных отрезков  $[x_{i-1}, x_i]$  длины  $h_i$ . Таким образом, в роли конечного элемента выступает элементарный отрезок  $[x_{i-1}, x_i]$ .

Введем базисные функции  $\varphi_j(x)$  для  $j = 1, 2, \dots, N - 1$  следующим образом

$$\varphi_j(x) = \begin{cases} (x - x_{j-1})/h_j & \text{при } x \in [x_{j-1}, x_j], \\ (x_{j+1} - x)/h_{j+1} & \text{при } x \in [x_j, x_{j+1}], \\ 0 & \text{при } x \notin [x_{j-1}, x_{j+1}]. \end{cases} \quad (15.77)$$

График такой базисной функции ("шапочки") изображен на рис. 15.2. Подчеркнем, что функция  $\varphi_j$  отлична от нуля только лишь на двух

---

<sup>1</sup> Рихард Курант (1888—1972) — немецкий математик.

соседних конечных элементах (отрезках  $[x_{j-1}, x_j]$  и  $[x_j, x_{j+1}]$ ) и является кусочно-линейной.

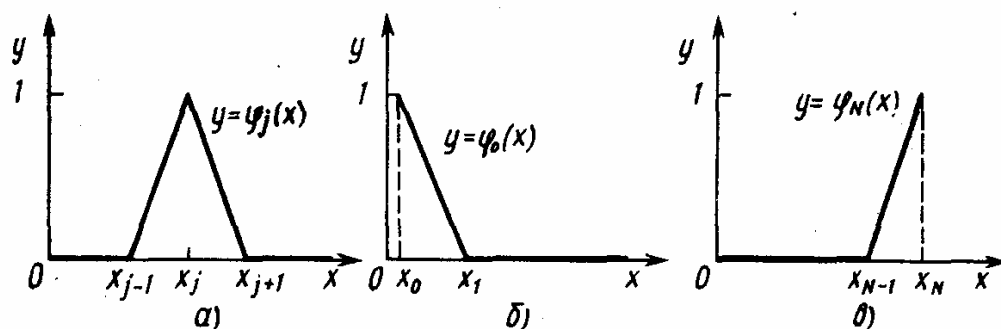


Рис. 15.2

Введем также функции  $\varphi_j(x)$  для  $j = 0$  и  $j = N$  (рис. 15.2, а, б):

$$\varphi_0(x) = \begin{cases} (x_1 - x)/h_1 & \text{при } x \in [x_0, x_1], \\ 0 & \text{при } x \notin [x_0, x_1]; \end{cases} \quad (15.78)$$

$$\varphi_N(x) = \begin{cases} 0 & \text{при } x \notin [x_{N-1}, x_N], \\ (x - x_{N-1})/h_N & \text{при } x \in [x_{N-1}, x_N]. \end{cases} \quad (15.79)$$

Будем искать приближенное решение задачи в виде

$$u^N(x) = \sum_{j=0}^N \alpha_j \varphi_j(x). \quad (15.80)$$

Заметим, что базисные функции обладают тем свойством, что  $\varphi_j(x_j) = 1$  и  $\varphi_j(x_i) = 0$  при  $i \neq j$ . В силу этого  $\alpha_j = u^N(x_j)$ , т. е. коэффициенты линейной комбинации (15.80) представляют собой значения функции  $u^N$  в узлах  $x_j$ . После введения обозначения  $u_j^h = u^N(x_j)$  функцию (15.80) можно записать так:

$$u^N(x) = \sum_{j=0}^N u_j^h \varphi_j(x).$$

Величины  $u_j^h = \alpha_j$  ( $j = 0, 1, \dots, N$ ) удовлетворяют системе уравнений (15.69), (15.70), которую в данном случае можно получить как методом Рунге, так и методом Галеркина. Заметим, что базисные функции  $\varphi_i(x)$  и  $\varphi_j(x)$  одновременно могут быть отличны от нуля только, если  $|i - j| \leq 1$ . Поэтому при  $|i - j| > 1$  элементы  $a_{ij} = \int_a^b (k \varphi_i' \varphi_j' + q \varphi_i \varphi_j) dx$  равны нулю. Таким образом, для определения неизвестных  $u_j^h$  получаем следующую систему уравнений с трехдиагональной матрицей:

$$a_{i,i-1} u_{i-1}^h + a_{i,i} u_i^h + a_{i,i+1} u_{i+1}^h = b_i, \quad 1 \leq i \leq N-1, \quad (15.81)$$

$$u_0^h = u_a, \quad u_N^h = u_b. \quad (15.82)$$

Так как

$$\varphi_j'(x) = \begin{cases} 1/h_j & \text{при } x \in (x_{j-1}, x_j), \\ -1/h_{j+1} & \text{при } x \in (x_j, x_{j+1}), \\ 0 & \text{при } x \notin [x_{j-1}, x_{j+1}], \end{cases}$$

то

$$a_{i,i-1} = -k_{i-1/2}^h / h_i + h_{i+1/2} q_{i-1/2}^h, \quad a_{i,i+1} = -k_{i+1/2}^h / h_{i+1} + h_{i+1/2} q_{i+1/2}^h, \quad (15.83)$$

$$a_{i,i} = k_{i-1/2}^h / h_i + k_{i+1/2}^h / h_{i+1} + h_{i+1/2} q_i^h, \quad b_i = h_{i+1/2} f_i^h, \quad (15.84)$$

где

$$k_{i-1/2}^h = \frac{1}{h_i} \int_{x_{i-1}}^{x_i} k(x) dx, \quad q_{i-1/2}^h = \frac{1}{h_{i+1/2}} \int_{x_{i-1}}^{x_i} q \varphi_i \varphi_{i-1} dx, \quad (15.85)$$

$$q_i^h = \frac{1}{h_{i+1/2}} \int_{x_{i-1}}^{x_{i+1}} q \varphi_i^2 dx, \quad f_i^h = \frac{1}{h_{i+1/2}} \int_{x_{i-1}}^{x_{i+1}} f \varphi_i dx. \quad (15.86)$$

Систему уравнений (15.81), (15.82) принято называть системой метода конечных элементов или *проекционно-разностной схемой*<sup>1</sup>.

Можно показать, что проекционно-разностная схема имеет единственное решение  $u^N(x)$  и при выполнении некоторых условий на сетку  $\bar{\omega}^h$  и коэффициенты  $k, q, f$  она имеет второй порядок точности.

Существует весьма тесная связь между теорией разностных схем и теорией проекционно-разностных схем. В подтверждение сказанного ограничимся тем, что преобразуем систему (15.81), (15.82) так, чтобы она обрела внешнее сходство с соответствующей разностной схемой. Разделив каждое уравнение (15.81) на  $h_{i+1/2}$  и воспользовавшись равенствами (15.83)–(15.87), получим систему уравнений

<sup>1</sup> Используется также термин *проекционно-сеточный метод*. Та же система уравнений может называться *вариационно-разностной схемой*, если она получена с помощью метода Рунге.



$$-\frac{1}{h_{i+1/2}} \left[ k_{i+1/2}^h \frac{u_{i+1}^h - u_i^h}{h_{i+1}} - k_{i-1/2}^h \frac{u_i^h - u_{i-1}^h}{h_i} \right] + \quad (15.87)$$

$$+ q_{i-1/2}^h u_{i-1}^h + q_i^h u_i^h + q_{i+1/2}^h u_{i+1}^h = f_i^h,$$

$$u_0^h = u_a, \quad u_N^h = u_b. \quad (15.88)$$

В такой форме записи она действительно оказывается похожа на разностную схему (15.55), (15.56).

**З а м е ч а н и е.** При построении системы уравнений метода конечных элементов, как правило, возникает необходимость вычисления некоторых интегралов<sup>1</sup>. Для проекционно-разностной схемы (15.87), (15.88) в случае, когда коэффициенты  $k$ ,  $q$ ,  $f$  — гладкие, эта проблема легко решается применением квадратурных формул. Например, можно положить

$$\begin{aligned} \int_{x_{i-1}}^{x_i} k(x) dx &\approx h_i k(x_{i-1/2}), \quad \int_{x_{i-1}}^{x_i} q(x) \varphi_i(x) \varphi_{i-1}(x) dx \approx \\ &\approx q(x_{i-1/2}) \int_{x_{i-1}}^{x_i} \frac{(x - x_{i-1})(x_i - x)}{h_i} dx = \frac{h_i}{6} q(x_{i-1/2}), \\ \int_{x_{i-1}}^{x_{i+1}} q(x) \varphi_i^2(x) dx &\approx q(x_{i-1/2}) \int_{x_{i-1}}^{x_i} \frac{(x - x_{i-1})^2}{h_i^2} dx + q(x_{i+1/2}) \int_{x_i}^{x_{i+1}} \frac{(x_{i+1} - x)^2}{h_{i+1}^2} dx = \\ &= \frac{h_i}{3} q(x_{i-1/2}) + \frac{h_{i+1}}{3} q(x_{i+1/2}), \\ \int_{x_{i-1}}^{x_{i+1}} f(x) \varphi_i dx &\approx f(x_{i-1/2}) \int_{x_{i-1}}^{x_i} \frac{x - x_{i-1}}{h_i} dx + f(x_{i+1/2}) \int_{x_i}^{x_{i+1}} \frac{x_{i+1} - x}{h_{i+1}} dx = \\ &= \frac{h_i}{2} f(x_{i-1/2}) + \frac{h_{i+1}}{2} f(x_{i+1/2}). \end{aligned}$$

При этом второй порядок точности сохраняется.

**7. Специальная проекционно-разностная схема.** Предположим, что коэффициенты  $k$ ,  $q$ ,  $f$ , входящие в одномерное уравнение диффузии (15.63), могут быть разрывными. В этом случае можно, как и ранее, использовать кусочно-линейные базисные функции (15.77), (15.78),

<sup>1</sup> Аналогичная проблема возникает и при реализации некоторых разностных схем, например, однородной разностной схемы (15.55), (15.56).

(15.79). Полученная таким образом проекционно-разностная схема сходится, однако по скорости сходимости она существенно уступает однородной разностной схеме (15.55), (15.56).

Чтобы получить качественную проекционно-разностную схему для уравнения диффузии с разрывными коэффициентами, воспользуемся специальными базисными функциями  $\varphi_j(x)$ . Эти функции для  $j = 1, 2, \dots, N-1$  имеют следующий вид:

$$\varphi_j(x) = \begin{cases} \frac{1}{\Delta_j} \int_{x_{j-1}}^x \frac{dy}{k(y)} & \text{при } x \in [x_{j-1}, x_j], \\ \frac{1}{\Delta_{j+1}} \int_x^{x_{j+1}} \frac{dy}{k(y)} & \text{при } x \in [x_j, x_{j+1}], \\ 0 & \text{при } x \notin [x_{j-1}, x_{j+1}]. \end{cases} \quad (15.89)$$

Здесь  $\Delta_j = \int_{x_{j-1}}^{x_j} \frac{dy}{k(y)}$ ,  $\Delta_{j+1} = \int_{x_j}^{x_{j+1}} \frac{dy}{k(y)}$ . Кроме того,

$$\varphi_0(x) = \begin{cases} \frac{1}{\Delta_1} \int_x^{x_1} \frac{dy}{k(y)} & \text{при } x \in [x_0, x_1], \\ 0 & \text{при } x \notin [x_0, x_1]; \end{cases} \quad (15.90)$$

$$\varphi_N(x) = \begin{cases} 0 & \text{при } x \notin [x_{N-1}, x_N], \\ \frac{1}{\Delta_N} \int_{x_{N-1}}^x \frac{dy}{k(y)} & \text{при } x \in [x_{N-1}, x_N]. \end{cases} \quad (15.91)$$

Выбранные базисные функции  $\varphi_j$  интересны тем, что всюду за исключением узлов сетки они удовлетворяют дифференциальному уравнению  $(k\varphi_j')' = 0$ .

Применение этих базисных функций приводит к проекционно-разностной схеме вида (15.87), (15.88), где все коэффициенты находятся по формулам (15.85), (15.86) за исключением коэффициентов  $k_{i-1/2}^h$ ,  $k_{i+1/2}^h$ , которые вычисляются по формулам

$$k_{i-1/2}^h = \left[ \frac{1}{h_i} \int_{x_{i-1}}^{x_i} \frac{dx}{k(x)} \right]^{-1}, \quad k_{i+1/2}^h = \left[ \frac{1}{h_{i+1}} \int_{x_i}^{x_{i+1}} \frac{dx}{k(x)} \right]^{-1},$$

т. е. так же, как и в разностной схеме (15.55), (15.56).

Эта проекционно-разностная схема имеет второй порядок точности

и решается методом прогонки. Отметим одно замечательное свойство указанной схемы. В случае  $q(x) \equiv 0$  полученные с ее помощью значения  $u_i^h$  совпадают с истинными значениями краевой задачи  $u(x_i)$  в узлах сетки (схема точна в узлах сетки). Отметим, что базисные функции (15.89), (15.90), (15.91) и в случае, когда коэффициенты уравнения диффузии являются гладкими, но сильно меняющимися, дают большую точность по сравнению с простейшими кусочно-линейными базисными функциями.

## § 15.5. Метод пристрелки

*Метод пристрелки* (он называется также *методом стрельбы* или *баллистическим методом*) позволяет свести решение краевой задачи к решению системы нелинейных уравнений относительно так называемых пристрелочных параметров, а также к решению (вообще говоря, многократному) задачи Коши.

Сначала рассмотрим этот метод на примере решения следующей краевой задачи для системы двух дифференциальных уравнений первого порядка:

$$y'(x) = f(x, y(x), z(x)), \quad (15.92)$$

$$z'(x) = g(x, y(x), z(x)), \quad (15.93)$$

$$y(a) = y_a, \quad z(b) = z_b. \quad (15.94)$$

Наряду с этой задачей рассмотрим задачу Коши

$$y'(x, \alpha) = f(x, y(x, \alpha), z(x, \alpha)), \quad (15.95)$$

$$z'(x, \alpha) = g(x, y(x, \alpha), z(x, \alpha)), \quad (15.96)$$

$$y(a) = y_a, \quad z(a) = \alpha. \quad (15.97)$$

Решение задачи (15.95)–(15.97), т. е. пара функций  $y(x, \alpha)$ ,  $z(x, \alpha)$ , зависит не только от переменной  $x$ , но и от *пристрелочного параметра*  $\alpha$ . Подбрав значение параметра  $\alpha$ , при котором  $z(b, \alpha) = z_b$ , получим решение задачи Коши, совпадающее с решением краевой задачи (15.92)–(15.94).

Таким образом, для того чтобы найти решение краевой задачи нужно решить нелинейное уравнение

$$\psi(\alpha) = 0, \quad (15.98)$$

где  $\psi(\alpha) = z(b, \alpha) - z_b$ . Отметим, что функция  $\psi(\alpha)$  не задана какой-либо явной формулой и вычисление каждого ее значения предполагает

вычисление решения задачи Коши (15.95)–(15.97). Как правило, для решения задачи Коши приходится использовать тот или иной численный метод.

Уравнение (15.98) можно решать, используя один из известных методов решения нелинейных уравнений. Довольно часто успешным оказывается применение метода бисекции, метода секущих или метода Ньютона (см. гл. 4).

**З а м е ч а н и е.** Применение метода Ньютона

$$\alpha_{k+1} = \alpha_k - \psi(\alpha_k)/\psi'(\alpha_k) \quad (15.99)$$

сопряжено с необходимостью вычисления значений не только функции  $\psi(\alpha)$ , но и ее производной  $\psi'(\alpha)$ . Покажем, как можно вычислить  $\psi'(\alpha) = \frac{\partial}{\partial \alpha} z(b, \alpha)$  в рассматриваемом случае.

Дифференцируя по параметру  $\alpha$  уравнения (15.95), (15.96) и начальные условия (15.97), замечаем, что функции  $u(x, \alpha) = \frac{\partial}{\partial \alpha} y(x, \alpha)$ ,  $v(x, \alpha) = \frac{\partial}{\partial \alpha} z(x, \alpha)$  удовлетворяют следующим уравнениям и начальным условиям:

$$u' = f'_y(x, y(x, \alpha), z(x, \alpha))u + f'_z(x, y(x, \alpha), z(x, \alpha))v, \quad (15.100)$$

$$v' = g'_y(x, y(x, \alpha), z(x, \alpha))u + g'_z(x, y(x, \alpha), z(x, \alpha))v, \quad (15.101)$$

$$u(a, \alpha) = 0, v(a, \alpha) = 1. \quad (15.102)$$

Решая теперь относительно функций  $y, z, u, v$  задачу Коши для системы уравнений (15.95), (15.96), (15.100), (15.101) с начальными условиями (15.97), (15.102), можно определить  $\psi(\alpha) = z(b, \alpha) - z_b$  и  $\psi'(\alpha) = v(b, \alpha)$ .

**Пример 15.2.** Применим метод пристрелки к решению краевой задачи

$$y'(x) = \frac{x}{z(x)}, \quad z'(x) = -\frac{x}{y(x)}, \quad 0 \leq x \leq 1 \quad (15.103)$$

$$y(0) = 1, \quad z(1) = 1. \quad (15.104)$$

Положим  $\psi(\alpha) = z(1, \alpha) - 1$ , где  $y(x, \alpha), z(x, \alpha)$  — решение задачи Коши

$$y'(x, \alpha) = \frac{x}{z(x, \alpha)}, \quad z'(x, \alpha) = -\frac{x}{y(x, \alpha)}, \quad (15.105)$$

$$y(0, \alpha) = 1, \quad z(0, \alpha) = \alpha. \quad (15.106)$$

Для решения уравнения  $\psi(\alpha) = 0$  воспользуемся методом секущих:

$$\alpha_{k+1} = \alpha_k - \psi(\alpha_k) \frac{\alpha_k - \alpha_{k-1}}{\psi(\alpha_k) - \psi(\alpha_{k-1})}. \quad (15.107)$$

Возьмем  $\alpha_0 = 0.5$ ,  $\alpha_1 = 1$  и будем вести итерации по формуле (15.107) до тех пор, пока не выполнится условие  $|\psi(\alpha_k)| < 10^{-6}$ . Результаты вычислений приведены в табл. 15.2.

Т а б л и ц а 15.2

$k$	$\alpha_k$	$\psi(\alpha_k)$
0	0.500000	-0.632121
1	1.000000	0.213061
2	0.873956	-0.013596
3	0.881517	$-0.167833 \cdot 10^{-3}$
4	0.881612	$0.151260 \cdot 10^{-6}$

Заметим, что в общем случае вычисление значения  $\psi(\alpha)$  производится с помощью численного решения задачи Коши. Однако в рассматриваемом случае задача (15.105), (15.106) допускает аналитическое решение

$$y(x, \alpha) = e^{\frac{x^2}{2\alpha}}, \quad z(x, \alpha) = 2\alpha e^{-\frac{x^2}{2\alpha}}. \quad (15.108)$$

Поэтому можно воспользоваться явной формулой

$$\psi(\alpha) = 2\alpha e^{-\frac{1}{2\alpha}} - 1.$$

В результате применения метода пристрелки для задачи (15.103), (15.104) получаем решение (15.108), где  $\alpha \approx 0.881612$ .

**З а м е ч а н и е.** Своим названием метод пристрелки обязан очевидной аналогии между процессом его реализации при решении краевой задачи и процессом пристрелки при артиллерийской стрельбе по цели. После выбора очередного значения  $\alpha_k$  пристрелочного параметра (выбора угла стрельбы) решается задача Коши (производится "выстрел"). Если  $z(b, \alpha_k)$  совпадает с  $z_b$  с заданной точностью, то "цель считается пораженной", а краевая задача — решенной. В противном случае производится корректировка значения пристрелочного параметра и процесс продолжается дальше.

Использование для решения уравнения (15.98) метода бисекции еще более усиливает эту аналогию. Здесь результат того "выстрела", при котором  $\psi(\alpha_k) > 0$ , может восприниматься как "перелет снаряда", а того, при котором  $\psi(\alpha_k) < 0$ , — как "недолет".

Покажем теперь схематично, как применяется метод пристрелки для решения общей двухточечной краевой задачи для системы дифференциальных уравнений первого порядка

$$\begin{aligned} y_1'(x) &= f_1(x, y_1(x), \dots, y_n(x)), \\ &\dots\dots\dots \\ y_n'(x) &= f_n(x, y_1(x), \dots, y_n(x)), \\ \varphi_1(y_1(a), \dots, y_n(a), y_1(b), \dots, y_n(b)) &= 0, \\ &\dots\dots\dots \\ \varphi_n(y_1(a), \dots, y_n(a), y_1(b), \dots, y_n(b)) &= 0. \end{aligned}$$

Запишем эту задачу в векторной форме:

$$y'(x) = f(x, y(x)), \quad (15.109)$$

$$\varphi(y(a), y(b)) = 0. \quad (15.110)$$

Рассмотрим также задачу Коши

$$y'(x, \alpha) = f(x, y(x, \alpha)), \quad (15.111)$$

$$y(a, \alpha) = \alpha. \quad (15.112)$$

Здесь  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^T$  — вектор пристрелочных параметров. Решив задачу Коши (15.111), (15.112) при фиксированном значении вектора  $\alpha$ , получим решение  $y(x, \alpha)$ . Далее взяв  $y(a) = \alpha$  и  $y(b) = y(b, \alpha)$  и подставив эти значения в систему (15.110), приходим к системе уравнений

$$\psi(\alpha) = 0, \quad (15.113)$$

где  $\psi(\alpha) = \varphi(\alpha, y(b, \alpha))$ . Наконец, решив систему (15.113), получаем набор  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^T$  значений пристрелочных параметров, при которых решение задачи Коши (15.111), (15.112) совпадает с решением краевой задачи (15.109), (15.110).

Практическая реализация метода пристрелки при большом числе уравнений (часто уже при  $n \geq 3$ ) оказывается довольно сложным делом. Действительно, даже сама по себе проблема решения системы

нелинейных уравнений (15.113) является весьма трудной. Серьезные затруднения могут возникнуть здесь уже на этапе выбора хорошего начального приближения  $\alpha_0$ . Необходимо также учесть, что каждое вычисление вектор-функции  $\psi(\alpha)$  является здесь весьма трудоемкой операцией: оно предполагает (численное) решение задачи Коши (15.111), (15.112).

Метод пристрелки достаточно эффективен в том случае, когда задача Коши (15.111), (15.112) является хорошо обусловленной. Однако если задача Коши плохо обусловлена, то метод оказывается практически непригодным. Дело в том, что при решении системы (15.113) значения пристрелочных параметров  $\alpha$  обязательно будут найдены с некоторой погрешностью, (относительная величина которой не может иметь порядок, меньший чем машинное эpsilon  $\epsilon_M$ ). Соответствующее решение задачи Коши (в случае плохой обусловленности) в результате этой погрешности окажется полностью искаженным. Однако даже в том идеализированном случае, когда вектор  $\alpha$  найден абсолютно точно, при численном решении задачи (15.111), (15.112) на ЭВМ в приближенное решение будут внесены ошибки, которые сделают его непригодным. Для некоторых систем эти ошибки могут приводить даже к аварийному останову вычислительного процесса.

**Пример 15.3.** Рассмотрим краевую задачу

$$y'(x) = z(x), \quad z'(x) = 100y(x) + e^x, \quad 0 \leq x \leq 2, \quad (15.114)$$

$$y(0) = 0, \quad z(2) = 0. \quad (15.115)$$

Как нетрудно проверить, ее решением является пара функций

$$y(x) = c_1 e^{10x} + c_2 e^{-10x} - \frac{e^x}{99},$$

$$z(x) = 10c_1 e^{10x} - 10c_2 e^{-10x} - \frac{e^x}{99},$$

где

$$c_1 = \frac{1}{990} \frac{10e^{-40} + e^{-18}}{1 + e^{-40}} \approx 1.53838 \cdot 10^{-11},$$

$$c_2 = \frac{1}{990} \frac{10 - e^{-18}}{1 + e^{-40}} \approx 0.0101010.$$

Попробуем решить задачу (15.114), (15.115) методом пристрелки, используя 6-разрядную десятичную ЭВМ. Соответствующая задача Коши имеет вид

$$y'(x, \alpha) = z(x, \alpha), \quad z'(x, \alpha) = 100y(x, \alpha) + e^x,$$

$$y(0, \alpha) = 0, \quad z(0, \alpha) = \alpha.$$

Ее решением являются функции

$$y(x, \alpha) = \frac{1}{20} \left[ \frac{1}{9} + \alpha \right] e^{10x} + \frac{1}{20} \left[ \frac{1}{11} - \alpha \right] e^{-10x} - \frac{1}{99} e^x, \quad (15.116)$$

$$z(x, \alpha) = \frac{1}{2} \left[ \frac{1}{9} + \alpha \right] e^{10x} - \frac{1}{2} \left[ \frac{1}{11} - \alpha \right] e^{-10x} - \frac{1}{99} e^x. \quad (15.117)$$

Уравнение  $\psi(\alpha) = 0$  (где  $\psi(\alpha) \equiv z(2, \alpha)$ ) для определения пристрелочного параметра  $\alpha$  является линейным. Поэтому для определения  $\alpha$  достаточно сделать одну итерацию метода секущих:

$$\alpha = \alpha_1 - \frac{\psi(\alpha_1)(\alpha_1 - \alpha_0)}{\psi(\alpha_1) - \psi(\alpha_0)}. \quad (15.118)$$

Возьмем  $\alpha_0 = 0$ ,  $\alpha_1 = -1$ . Тогда вычисления по формуле (15.117) на 6-разрядной десятичной ЭВМ дают значения  $\psi(\alpha_0) = z(2, 0) \approx 2.69536 \cdot 10^7$ ,  $\psi(\alpha_1) = z(2, -1) \approx -2.15629 \cdot 10^8$ . В соответствии с формулой (15.118) получается следующее значение пристрелочного параметра:

$$\alpha = -1 - \frac{-2.15629 \cdot 10^8(-1 - 0)}{-2.15629 \cdot 10^8 - 2.69536 \cdot 10^7} \approx \alpha^* = -1 + 0.888888 = -0.111112.$$

Подстановка в формулы (15.116), (15.117) значения  $\alpha = \alpha^*$  приводит к приближенному решению

$$y^*(x) = c_1^* e^{10x} + c_2^* e^{-10x} - \frac{1}{99} e^x,$$

$$z^*(x) = 10c_1^* e^{10x} - 10c_2^* e^{-10x} - \frac{1}{99} e^x.$$

Здесь

$$c_1^* = \frac{1}{20} \left[ \frac{1}{9} + \alpha^* \right] \approx \frac{1}{20} (0.111111 - 0.111112) = -5 \cdot 10^{-8},$$

$$c_2^* = \frac{1}{20} \left[ \frac{1}{11} - \alpha^* \right] \approx \frac{1}{20} (0.0909091 + 0.111112) \approx 0.0101011.$$

Тогда  $c_1 - c_1^* \approx 5 \cdot 10^{-8}$ ,  $c_2 - c_2^* \approx -10^{-7}$ . Это означает, что

$$y(x) - y^*(x) \approx 5 \cdot 10^{-8} e^{10x} - 10^{-7} e^{-10x},$$

$$z(x) - z^*(x) \approx 5 \cdot 10^{-7} e^{10x} + 10^{-6} e^{-10x}.$$

Наличие в погрешности компоненты, пропорциональной  $e^{10x}$ , приводит к тому, что при  $x = 2$  погрешности решения достигают следующих величин:  $y(2) - y^*(2) \approx 24.3$ ,  $z(2) - z^*(2) \approx 243$ .



## § 15.6. Дополнительные замечания

1. В этой главе метод конечных разностей и метод конечных элементов рассматривались только лишь применительно к решению двухточечных краевых задач для обыкновенных дифференциальных уравнений второго порядка. Значительно более широкую область применения этих методов представляют собой различные задачи для дифференциальных уравнений в частных производных. Ограниченный объем книги не позволяет отразить здесь богатство существующих подходов и разнообразие используемых приемов. Тем, кто интересуется решением уравнений в частных производных с помощью метода конечных разностей, рекомендуем первоначально обратиться к учебникам [43], [60], [71], а затем — к книгам [54], [70].

Как доступное введение в метод конечных элементов, можно рекомендовать книги [3], [27], [57], [75]. В дальнейшем следует обратиться к [35], [36], [55], [73], [85].

2. Так как мы рассматривали краевые задачи только для обыкновенных дифференциальных уравнений, то тем самым фактически лишили себя возможности обсуждать достоинства и недостатки метода конечных разностей и метода конечных элементов в их сравнении между собой. Ограничимся лишь констатацией того, что для решения дифференциальных уравнений существуют два мощных метода, каждый из которых не обладает, вообще говоря, безусловным преимуществом над другим. Тем не менее отметим, что нередко наиболее эффективными оказываются именно те приближенные методы, которые сочетают в себе достоинства обоих методов.

3. При математическом моделировании различных физических явлений часто приходится решать краевые задачи, в которых дифференциальные уравнения или краевые условия являются нелинейными. Примером может служить дифференциальное уравнение  $-(k(x, u)u')' = f(x, u)$ , описывающее установившееся распределение тепла в стержне, теплофизические характеристики которого зависят от температуры  $u$ . Для решения таких задач широко используются метод конечных разностей и метод конечных элементов. Возникающие здесь дискретные краевые задачи нелинейны и требуют для вычисления решений использования специальных итерационных методов.

4. В последние десятилетия было осознано, что решение проблемы численного решения дифференциальных уравнений основано на использовании специальных методов теории приближения функций. Однако глубокая связь между проблемой аппроксимации функций и проблемой решения дифференциальных уравнений осталась за рамками данной книги. Отметим лишь, что приближенное решение  $u^N(x)$ , полученное с помощью проекционно-разностной схемы (15.81), (15.82), представляет собой линейный сплайн.

## ЛИТЕРАТУРА

1. Абрамовиц М., Стиган И. (ред.). Справочник по специальным функциям с формулами, графиками и математическими таблицами. — М.: Наука, 1979.
2. Алберг Дж., Нилсон Э., Уолш Дж. Теория сплайнов и ее приложения. — М.: Мир, 1972.
3. Андреев В.Б., Руховец Л.А. Проекционные методы. — М.: Знание, 1986.
4. Бабенко К.И. Основы численного анализа. — М.: Наука, 1986.
5. Бабушка И., Витасек Э., Прагер М. Численные процессы решения дифференциальных уравнений. — М.: Мир, 1969.
6. Базара М., Шетти К. Нелинейное программирование. Теория и алгоритмы. — М.: Мир, 1982.
7. Бакушинский А.Б., Гончарский А.В. Некорректные задачи. Численные методы и приложения. — М.: Изд-во МГУ, 1989.
8. Бахвалов Н.С. Численные методы. — М.: Наука, 1973.
9. Бахвалов Н.С., Жидков Н.П., Кобельков Г.М. Численные методы. — М.: Наука, 1987.
10. Безбородов Ю.М. Индивидуальная отладка программ. — М.: Наука, 1982.
11. Бейкер Дж., Грейвс — Моррис П. Аппроксимации Паде. — М.: Мир, 1986.
12. Беклемишев Д.В. Дополнительные главы линейной алгебры. — М.: Наука, 1983.
13. Блехман Н.Н., Мышкис А.Д., Пановко Я.Г. Механика и прикладная математика. Логика и особенности приложений математики. — М.: Наука, 1983.
14. Боглаев Ю.П. Вычислительная математика и программирование. — М.: Высшая школа, 1990.
15. Боголюбов А.Н. Математики. Механики. Биографический справочник. — Киев: Наукова думка, 1983.
16. Де Бор К. Практическое руководство по сплайнам. — М.: Радио и связь, 1985.
17. Бородин А.Н., Бугай А.С. Выдающиеся математики. — Киев: Радянська школа, 1987.

18. В а с и л ь е в Ф.П. Численные методы решения экстремальных задач. — М.: Наука, 1980.
19. В о е в о д и н В.В. Вычислительные основы линейной алгебры. — М.: Наука, 1977.
20. В о е в о д и н В.В., К у з н е ц о в Ю.А. Матрицы и вычисления. — М.: Наука, 1984.
21. В о л к о в Е.А. Численные методы. — М.: Наука, 1987.
22. Г а л л а г е р Р. Метод конечных элементов. Основы. — М.: Мир, 1984.
23. Г а н т м а х е р Ф.Р. Теория матриц. — М.: Наука, 1988.
24. Г и л л Ф., М ю р р е й У., Р а й т М. Практическая оптимизация. — М.: Мир, 1985.
25. Г о р и н ш т е й н А.М. Практика решения инженерных задач на ЭВМ. — М.: Радио и связь, 1984.
26. Д е к к е р К., В е р в е р Я. Устойчивость методов Рунге—Кутты для жестких нелинейных дифференциальных уравнений. — М.: Мир, 1988.
27. Д е к л у Ж. Метод конечных элементов. — М.: Мир, 1976.
28. Д е м и д о в и ч Б.П., М а р о н И.А. Основы вычислительной математики. — М.: Наука, 1966.
29. Д е м и д о в и ч Б.П., М а р о н И.А., Ш у в а л о в а Э.З. Численные методы анализа. — М.: Наука, 1967.
30. Д ж о р д ж А., Л ю Дж. Численное решение больших разреженных систем уравнений. — М.: Мир, 1984.
31. Д ж о у н с У., Т р о н В. Непрерывные дроби. — М.: Мир, 1985.
32. Д э н н и с Дж., Ш н а б е л ь Р. Численные методы безусловной оптимизации и решения нелинейных уравнений. — М.: Мир, 1988.
33. Ж а б л о н К., С и м о н Ж.—К. Применение ЭВМ для численного моделирования в физике. — М.: Наука, 1983.
34. З а в ь я л о в Ю.С., К в а с о в Б.И., М и р о ш н и ч е н к о В.Л. Методы сплайн-функций. — М.: Наука, 1980.
35. З е н к е в и ч О. Метод конечных элементов в технике. — М.: Мир, 1975.
36. З е н к е в и ч О., М о р г а н К. Конечные элементы и аппроксимация. — М.: Мир, 1986.
37. И в а н о в В.В. Методы вычислений на ЭВМ. Справочное пособие. — Киев: Наукова думка, 1986.
38. И к р а м о в Х.Д. Численные методы линейной алгебры. (Решение линейных уравнений.) — М.: Знание, 1987.
39. И к р а м о в Х.Д. Численные методы для симметричных линейных систем. — М.: Наука, 1988.
40. И к р а м о в Х.Д. Вычислительные методы линейной алгебры. (Реше-

ние больших разреженных систем уравнений прямыми методами.) — М.: Знание, 1989.

41. И к р а м о в Х.Д. Несимметричная проблема собственных значений. — М.: Наука, 1991.

42. И л ь и н В.П., К у з н е ц о в Ю.И. Трехдиагональные матрицы и их приложения. — М.: Наука, 1985.

43. К а л и т к и н Н.Н. Численные методы. — М.: Наука, 1978.

44. К а н т о р о в и ч А.В., А к и л о в Г.П. Функциональный анализ. — М.: Наука, 1977.

45. К а р п о в В.Я., К о р я г и н Д.А. Пакеты прикладных программ. — М.: Знание, 1983.

46. К о п ч е н о в а Н.В., М а р о н И.А. Вычислительная математика в примерах и задачах. — М.: Наука, 1972.

47. К р а с н о щ е к о в П.С., П е т р о в А.А. Принципы построения моделей. — М.: Изд-во МГУ, 1983.

48. К р о н р о д А.С. Узлы и веса квадратурных формул. — М.: Наука, 1964.

49. К р ы л о в В.И., Б о б к о в В.В., М о н а с т ы р н ы й П.Н. Вычислительные методы, том 1. — М.: Наука, 1976.

50. Л о у с о н У., Х е н с о н Р. Численное решение задач метода наименьших квадратов. — М.: Наука, 1986.

51. Л ю к Ю. Специальные математические функции и их аппроксимации. — М.: Мир, 1980.

52. Л ю с т е р н и к Л.А., Ч е р в о н е н к и с О.А., Я н п о л ь с к и й А.Р. Математический анализ. Вычисление элементарных функций. М.: Физматгиз, 1963.

53. М а к-К р а к е н Д., Д о р н У. Численные методы и программирование на ФОРТРАНЕ. — М.: Мир, 1977.

54. М а р ч у к Г.И. Методы вычислительной математики. — М.: Наука, 1989.

55. М а р ч у к Г.И., А г о ш к о в В.И. Введение в проекционно-сеточные методы. — М.: Наука, 1981.

56. М а р ч у к Г.И., Ш а й д у р о в В.В. Повышение точности решений разностных схем. — М.: Наука, 1979.

57. М и т ч е л л Э., У а й т Р. Метод конечных элементов для уравнений с частными производными. — М.: Мир, 1981.

58. М о и с е е в Н.Н. Математика ставит эксперимент. — М.: Наука, 1979.

59. М о р о з о в В.А. Регулярные методы решения некорректно поставленных задач. — М.: Наука, 1987.

60. О р т е г а Дж., П у л У. Введение в численные методы решения дифференциальных уравнений. — М.: Наука, 1986.

61. Ортега Д., Рейнболдт В. Итерационные методы решения нелинейных систем уравнений со многими неизвестными. — М.: Мир, 1975.
62. Парлетт Б. Симметричная проблема собственных значений. — М.: Мир, 1983.
63. Писсанецки С. Технология разреженных матриц. — М.: Мир, 1988.
64. Поляк Б.Т. Введение в оптимизацию. — М.: Наука, 1983.
65. Попов Ю.П., Самарский А.А. Вычислительный эксперимент. — М.: Знание, 1983.
66. Пшеничный Б.Н., Данилин Ю.М. Численные методы в экстремальных задачах. — М.: Наука, 1975.
67. Райс Дж. Матричные вычисления и математическое обеспечение. — М.: Мир, 1984.
68. Ракитский Ю.В., Устинов С.М., Черноруцкий М.Г. Численные методы решения жестких систем. — М.: Наука, 1979.
69. Самарский А.А. Введение в численные методы. — М.: Наука, 1982.
70. Самарский А.А. Теория разностных схем. — М.: Наука, 1977.
71. Самарский А.А., Гулин А.В. Численные методы. — М.: Наука, 1989.
72. Самарский А.А., Николаев Е.С. Методы решения сеточных уравнений. — М.: Наука, 1978.
73. Сегерлинд Л. Применение метода конечных элементов. — М.: Мир, 1979.
74. Современные численные методы решения обыкновенных дифференциальных уравнений (под ред. Дж. Холла и Дж. Уатта). — М.: Мир, 1979.
75. Стренг Г., Фикс Дж. Теория метода конечных элементов. — М.: Мир, 1977.
76. Сухарев А.Г., Тимохов А.В., Федоров В.В. Курс методов оптимизации. — М.: Наука, 1986.
77. Сьярле Ф. Метод конечных элементов для эллиптических задач. — М.: Мир, 1980.
78. Тихонов А.Н. Математическая модель. Математическая энциклопедия, т. 3. — Сов. энциклоп., 1982.
79. Тихонов А.Н., Арсенин В.Я. Методы решения некорректных задач. — М.: Наука, 1986.
80. Тихонов А.Н., Гончарский А.В., Степанов В.В., Ягола А.Г. Численные методы решения некорректных задач. — М.: Наука, 1990.
81. Тихонов А.Н., Костомаров Д.П. Вводные лекции по прикладной математике. — М.: Наука, 1984.
82. Тьюарсон Р. Разреженные матрицы. — М.: Мир, 1977.

83. У и л к и н с о н Дж. Х. Алгебраическая проблема собственных значений. — М.: Наука, 1970.

84. У и л к и н с о н Дж. Х., Р а й н ш К. Справочник алгоритмов на языке Алгол. Линейная алгебра. — М.: Машиностроение, 1976.

85. Ф л е т ч е р К. Численные методы на основе метода Галеркина. — М.: Мир, 1988.

86. Ф о р с а й т Дж., М а л ь к о м М., М о у л е р К. Машинные методы математических вычислений. — М.: Мир, 1980.

87. Ф о р с а й т Дж., М о л е р К. Численное решение систем линейных алгебраических уравнений. — М.: Мир, 1969.

88. Х а й р е р Э., Н е р с е т т С., В а н н е р Г. Решение обыкновенных дифференциальных уравнений. Нежесткие задачи. — М.: Мир, 1990.

89. Х е й г м а н Л., Я н г Д. Прикладные итерационные методы. — М.: Мир, 1986.

90. Х е м м и н г Р.В. Численные методы для научных работников и инженеров. — М.: Наука, 1972.

91. Х и м м е л ь б л а у Д. Прикладное нелинейное программирование. — М.: Мир, 1975.

92. Ш у п Т. Решение инженерных задач на ЭВМ. — М.: Мир, 1982.

93. Э л ь с г о л ь ц Л.Э. Дифференциальные уравнения и вариационное исчисление. — М.: Наука, 1969.

94. Э с т е р б ю О., З л а т е в З. Прямые методы для разреженных матриц. — М.: Мир, 1987.

## ПРЕДМЕТНЫЙ УКАЗАТЕЛЬ

- Абсолютная погрешность 25
  - - вектора 125
  - точность 28
  - устойчивость 459
- Абстрактный вычислительный алгоритм 63
- Автоматический выбор шага 445
- Адаптивные квадратурные программы 398
  - процедуры численного интегрирования 398
- Алгоритм бинарный 77
  - вычислительно устойчивый 65
  - вычислительный 63
  - - абстрактный 63
  - Гира 481, 482
  - Краута 173
  - неустойчивый 65
  - плохо обусловленный 71
  - устойчивый 65
  - хорошо обусловленный 70
  - *LR* 235
  - *QL* 235
  - *QR* 231
  - - основной 231
  - - со сдвигами 233
- Алгоритмы гибридные 111, 121, 260
  - регуляризованные 121, 260
- Анализ ошибок обратный 73
  - - прямой 72
  - - статистический 75
- Антиградиент 264
- Антипереполнение 39
- Апостериорные оценки погрешности 62
- Аппроксимационная теорема Вейерштрасса 324
- Аппроксимация дифференциального уравнения 424, 495
- 530
  - - - с  $p$ -м порядком 424
  - краевых условий 505
  - Паде 362
- Априорные оценки погрешности 61
  - - решения краевой задачи 486
  - - - разностной схемы 494
- Базис лагранжеев 330
  - локальный степенной 330
  - нормированный степенной 330
  - степенной 330
  - чебышевский 330
- Базисные многочлены 329
  - функции 508
  - - кусочно-линейные 514
  - - специальные 517
- Баллистический метод 518
- Быстрое дискретное преобразование Фурье 341
- Вариационная постановка краевой задачи 506
- Вариационно-разностная схема 515
- Вариационные принципы 506
- Вариационный функционал 506
- Вековое уравнение 212
- Векторы взаимно сопряженные 285
- Верная цифра 27
- Верхняя граница абсолютной погрешности 26
  - - относительной погрешности 26
- Вес 402
- Весовая функция 402
- Весы квадратурной формулы 376
  - - - Гаусса 390
- Временная постоянная 416
  - - локальная 417
- Входное данное 10, 12
- Вычислительная задача 12, 43
  - - корректная 43
  - - некорректная 44

- - плохо обусловленная 49
- - хорошо обусловленная 49
- погрешность 24
- Вычислительный алгоритм 63
  - - абстрактный 63
  - - корректный 63
  - - некорректный 63
  - - неустойчивый 65
  - - устойчивый 65
- процесс 19
- эксперимент 20
- Вычислительные методы 13, 55
- Гибридные алгоритмы 111, 121, 260
- Главный член погрешности квадратурной формулы 393
- Глобальная погрешность 425
  - полиномиальная интерполяция 324
- Градиент 264
- Градиентный метод 272
- Граница абсолютной погрешности 26
  - относительной погрешности 26
- Граничные условия 336
- Данные входные 10
  - выходные 10
  - исходные 10
- Двоичный порядок 37
- Двухточечная краевая задача 483
- Дефект сплайна 333
- Дискретизация 57
- Дискретная задача Коши 420
  - краевая задача 488
- Дискретное преобразование Фурье 340
  - - - быстрое 341
  - - - обратное 340
  - - - прямое 340
  - уравнение 419
- Диссипативная система дифференциальных уравнений 465
- Дробление шага 269
- Дробь непрерывная 362, 363
  - цепная 362, 363
- Евклидова норма вектора 124
  - - матрицы 127
- Естественный кубический сплайн 337
- Жесткая задача Коши 472, 478
  - система дифференциальных уравнений 477
- Жорданова форма матрицы 215
- Задача безусловной минимизации 262
  - вычислительная 12, 43
  - - корректная 44
  - - некорректная 44
  - - плохо обусловленная 49
  - - хорошо обусловленная 49
  - дискретной минимизации 291
  - жесткая 472
  - идентификации 11
  - интерполяции 295
  - - обобщенными многочленами 296
  - конечномерная 57
  - линейного программирования 291
  - Коши 410, 412
  - - дискретная 420
  - - для обыкновенного дифференциального уравнения первого порядка 412
  - - - - -  $m$ -го порядка 471
  - - - системы обыкновенных дифференциальных уравнений первого порядка 463
  - - жесткая 472, 476
  - - - для системы дифференциальных уравнений 476
  - краевая двухточечная 483
  - минимизации оценки погрешности интерполяции 306
  - начальная 410
  - наименьших квадратов линейная 343, 345, 363
  - - - нелинейная 355



- нелинейного программирования 291
- о наилучшем равномерном приближении 356
- о наименьших квадратах 290
- о понижении степени многочлена 358
- обратная 11
- одномерной минимизации 236
- прямая 10
- условной минимизации 262, 291

Золотое сечение 253

Значащая цифра 27

Инженерная задача 7

Интегральная кривая 411

Интегральное тождество 510

Интегрирование дифференциального уравнения 411

Интегро-интерполяционный метод 503

Интервал неопределенности корня нелинейного уравнения 88

- - точки локального минимума 242

Интерполирование 295

Интерполяционный массив 325

- многочлен 300
- - кубический Эрмита 305
- - Лагранжа 301
- - Ньютона с конечными разностями для интерполяции вперед 323
- - - - - для интерполяции назад 323
- - - с разделенными разностями 320
- - обобщенный 296
- - с кратными узлами 305

Интерполяция 295

- глобальная полиномиальная 324
- квадратичная 301
- кубическая 301
- кусочно-полиномиальная 332
- линейная 301

- локальная 331
- рациональная 361
- тригонометрическая 342

Искомое решение 10, 12

Исчезновение порядка 39

Исчерпывание 227

Итерационная последовательность 60

- функция 94

Итерационное уточнение 171

- - корней нелинейного уравнения 83, 85

Итерационные методы 59

Итерационный метод одношаговый 85

- -  $k$ -шаговый 85
- процесс 59

Итерация 59

Катастрофическая потеря точности 31, 69

Квазиньютоновские методы 283

Квазиньютоновское условие 283

Квадратурная сумма 376

- формула 376
- - Гаусса 389, 405
- - интерполяционного типа 385, 403
- - левых прямоугольников 378
- - Ньютона - Котеса 385
- - правых прямоугольников 378
- - прямоугольников элементарная 377
- - - составная 378
- - Симпсона элементарная 380
- - - составная 380
- - точная для многочленов степени  $m$  376
- - трапеций элементарная 378
- - - составная 378
- - центральных прямоугольников 378

Конечномерная задача 57

Конечно-разностная схема 452

Конечно-разностные методы 452

- шаги 205
- Конечные разности 311
  - вперед 311
  - назад 317
  - порядка  $k$  311
- Конечные элементы 513
- Константа Лебега 328
- Корень нелинейного уравнения 80
  - простой 81
  - кратный 81
- Корневое условие 455
- Корректность вычислительного алгоритма 63
  - вычислительной задачи 44
- Коэффициент роста 144
- Краевая задача двухточечная 483
  - дискретная 488
- Краевые условия первого рода 484
  - второго рода 484
- Кратность корня нелинейного уравнения 81
  - узла интерполяции 304
- Критерий окончания итерационного процесса 61, 270
- Круги Гершгорина 216
- Кубатурные формулы 408
- Кусочно-полиномиальная интерполяция 332
- Линейная задача наименьших квадратов 343, 345, 363
- Линия уровня 263
- Локализация корней нелинейного уравнения 83
  - собственных значений 216
  - точки минимума 241
- Локальная интерполяция 331
  - погрешность 424, 427
  - сходимость 111
- Локальный сплайн 335
- Ломаная Эйлера 430
- Мантисса 37
- Масштабирование 147
- Математическая модель 8
  - гипотетическая 9
  - динамическая 10
  - статическая 10
- Математическое моделирование 8
- Матрица
  - верхняя треугольная 129
  - Гессе 265
  - Гильберта 135
  - Грама 297
  - диагональная 128
  - единичная 128
  - заполненная 130
  - ленточная 131
  - нижняя треугольная 129
  - ортогональная 165
  - отражения 170
  - плотная 130
  - плохо обусловленная 133
  - подобия 214
  - положительно определенная 129
  - простой структуры 215
  - разреженная 130
  - симметричная 129
  - трехдиагональная 130
  - треугольная 129
  - Хаусхолдера 170
  - Хессенберга 233
  - Якоби 193
- Матрицы подобные 214
- Машинная бесконечность 39
  - точность 38
- Машинное слово 37
  - эpsilon 38, 42
- Машинный нуль 39
- Метод Адамса 448
  - интерполяционный 449
  - экстраполяционный 449
  - Адамса - Башфорта 449
  - Адамса - Моултона 449
  - баланса 503
  - баллистический 518

- бисекции 91, 257
- бисекций 235
- вращений 166
- - Якоби 235
- Галеркина 511
- Гаусса 137
- - с выбором главного элемента по всей матрице 145
- - - - - столбцу 143
- Гаусса - Зейделя 183
- градиентный 272
- Давиденко 210
- Данилевского 213
- деления отрезка пополам 247
- деформируемого многогранника 288
- дифференцирования по параметру 209
- Зейделя 182, 201
- золотого сечения 253
- итегро-интерполяционный 503
- касательных 106
- квадратных корней 158
- конечных разностей 487
- - элементов 512
- Крылова 213
- Ланцоша 189
- Леверье 213
- линейный многошаговый с чебышевским набором параметров 189
- ложного положения 113, 206
- минимальных невязок 189
- Монте - Карло 408
- Мюллера 121
- наименьших квадратов 173, 343
- наискорейшего спуска 189, 272
- Нумерова 472
- Ньютона вычисления  $\sqrt{a}$  60
- - минимизации 258, 280
- - решения нелинейных уравнений 106
- - - систем нелинейных уравнений 201
- - упрощенный 112, 205
- обратной квадратичной интерполяции 120
- обратных итераций 227
- - - с использованием отношения Рэлея 230
- отражений 170
- пассивного поиска 246
- покоординатного спуска 270
- половинного деления 91
- последовательного исключения неизвестных 137
- последовательной верхней релаксации 188
- - параболической интерполяции 259
- - нижней релаксации 188
- последовательных замещений 183
- пристрелки 518
- прогонки 161, 490
- продолжения по параметру 208
- простой итерации решения систем линейных алгебраических уравнений 175
- - - - систем нелинейных уравнений 196
- - - нелинейных уравнений 93
- релаксации 187
- Ритца 508
- Ромберга 398
- Рунге - Кутты 439
- - - неявный  $m$ -этапный 445
- - - четвертого порядка точности 443, 469
- - - явный  $m$ -этапный 441
- Рунге - Кутты - Фельберга 447, 482
- секущих 114, 206
- сеток 487
- сопряженных градиентов 189, 285

- - направлений 285
- Стеффенсена 116, 206
- степенной 221
- стохастической аппроксимации 261
- стрельбы 518
- установления 210
- Фибоначчи 250
- Холецкого 158
- Хьюна 437
- Эйлера 421, 430, 469
- - неявный 422, 461
- - усовершенствованный 438
- Эйлера - Коши 437
- экстраполяции Ричардсона 397
- Якоби 176
- *SOR* 187
- Метода Гаусса ведущий элемент  $k$ -го шага 138
  - - главный элемент  $k$ -го шага 138
  - - множители  $k$ -го шага 138
  - - обратный ход 139
  - - прямой ход 137
- Методы Адамса 448
  - аппроксимации 56
  - вычислительные 13, 55
  - итерационные 59
  - итерирования подпространства 235
  - квазиньютоновские 210, 283
  - конечно-разностные 452
  - линеаризации 57, 106
  - линейные многшаговые 452
  - Монте - Карло 62
  - "овражные" 277
  - одновременных итераций 235
  - переменной метрики 283
  - последовательного поиска 247
  - прогноза и коррекции 437, 451
  - прямого поиска 245, 287
  - прямые 58, 213
  - регуляризации 49, 58
  - Рунге - Кутты 439, 444, 481, 482
  - спуска 268
  - статистических испытаний 62
  - типа Ланцоша 235
  - - предиктор - корректор 437
  - точные 59
  - численные 13
  - эквивалентных преобразований 56
  - Минимальное значение функции 236, 262
  - Многочлен интерполяционный 300
    - - кубический Эрмита 305
    - - Ньютона 320, 323
    - - обобщенный 296
    - - с кратными узлами 305
    - Лагранжа 301
    - наилучшего равномерного приближения 356
    - - среднеквадратичного приближения 345
    - обобщенный 294
    - характеристический 455
  - Многочлены наименее уклоняющиеся от нуля 308
    - Чебышева 307
  - Модельное уравнение 416
  - Множество граничных узлов сетки 488
    - внутренних узлов сетки 488
    - возможных решений 43
    - допустимых входных данных 43
  - Надежность программы 78
  - Наименьших квадратов задача линейная 343, 345, 363
    - - - нелинейная 355
  - Наклон сплайна 334
  - Направление ньютоновское 280
    - спуска 268, 269
  - Начальная задача 410
  - Начальное значение 412
    - условие 412
  - Начальные значения 420

- условия 464, 471
- Невязка 123, 132
- Некорректная задача 44, 48
- Непрерывная дробь 362
- Неравенство треугольника 124
- Неустраняемая погрешность 24
- Неявный метод Эйлера 422, 461
- Норма вектора 124
  - - евклидова 124
  - матрицы подчиненная 126
  - - евклидова 127
- Нормальная система метода наименьших квадратов 345
- Нуль-устойчивость 454
- Область абсолютной устойчивости 459
  - неопределенности 73, 196
  - сходимости метода 60
- Обобщенный многочлен 294
- Обратная задача 11
  - прогонка 163
- Обратный анализ ошибок 73
  - ход метода Гаусса 139
  - - - прогонки 163
- Обусловленность вычислительного алгоритма 70
  - вычислительной задачи 49
- Односторонние формулы численного дифференцирования 371
- Округление 29
  - по дополнению 29
  - усечением 29
- Определитель Вандермонда 300
  - Грама 298
- Оптимальный пассивный поиск 246
- Остаточный член квадратурной формулы 376
- Относительная погрешность 25
  - - вектора 125
  - точность 29
  - - ЭВМ 38
- Отношение Рэлея 218

- Отражение 170
- Отрезок локализации корня нелинейного уравнения 83
  - - точки локального минимума 238
  - наблюдения 296
- Оценки погрешности априорные 61
  - - апостериорные 62
- Ошибка 25
  - округления 38
  - представления 38
- Пакет прикладных программ проблемно-ориентированный 22
- Параметр пристрелочный 518
  - релаксации 187
- Параметры модели 10
- Переносимость 78
- Переполнение 39
- Плоское вращение 168
- Плохо обусловленная вычислительная задача 49
  - - матрица 133
  - - система линейных алгебраических уравнений 133
- Плохо обусловленный вычислительный алгоритм 71
- Погрешность 23, 25
  - абсолютная 25
  - аппроксимации 56
  - - дискретного уравнения 424
  - - разностного уравнения 495
  - - формулы численного дифференцирования 365
  - вычислительная 24
  - квадратурной формулы 376
  - локальная 424
  - метода 24
  - на шаге 424
  - неустраняемая 24
  - округления 29
  - относительная 25
  - разностной схемы 496

- численного метода решения задачи Коши 425
- глобальная 425, 427
- локальная 424, 427
- Подобные матрицы 214
- Поверхность уровня 263
- Поддерживаемость 78
- Поле направлений 411
- Полином "движущийся" 331
  - устойчивости 459
- Портабельность 78
- Порядок сходимости итерационного метода 85
- Постановка краевой задачи вариационная 506
  - проекционная 510
- Постоянная временная 416
  - Липшица 412, 464
- Правило Гарвика 91
  - двойного пересчета 395, 445
  - Крамера 76
  - Рунге практической оценки погрешности 394, 445, 447, 497
  - трапеций 422, 436
- Представимое множество ЭВМ 38
- Преобразование Гивенса 168
  - подобия 214
  - Фурье дискретное 340
  - быстрое 341
  - обратное 340
  - прямое 340
  - Хаусхолдера 170
- Приближенное число 25
- Приведение к виду, удобному для итераций, системы линейных алгебраических уравнений 175
  - нелинейного уравнения 94, 100
- Пример Рунге 325
  - Уилкинсона 51, 219
- Принцип максимума 485, 492
  - - для системы сеточных уравнений 492
- Пристрелочные параметры 518, 521
- Проблема "оврагов" 276
  - собственных значений полная 212
  - частичная 212
- Пробная функция 510
- Пробные точки 245
- Прогонка обратная 163
  - прямая 162
- Прогоночные коэффициенты 162
- Проекционная постановка краевой задачи 510
- Проекционно-разностная схема 515
  - специальная 516
- Проекционно-разностный метод 515
- Порядок двоичный 37
  - сходимости итерационного метода 85
  - точности численного метода решения задачи Коши 425
- Процесс вычислительный 19
  - Либмана 183
- Прямая задача 10
  - прогонка 162
- Прямой анализ ошибок 72
  - ход метода Гаусса 137
  - прогонки 162
- Прямые методы 58
  - - решения проблемы собственных значений 213
- Работоспособность 78
- Разделенные разности 318
- Разложение матрицы на множители 154, 156, 166
  - LU 154
  - QR 166
- Разности конечные 311
  - - вперед 311
  - - назад 317
  - "против ветра" 503
  - "против потока" 503

- разделенные 318
- Разностная производная вторая 368
  - левая 365
  - правая 365
  - центральная 366
  - схема 452, 488, 490
  - однородная 505
- Разностное уравнение 489
  - $k$ -го порядка линейное однородное с постоянными коэффициентами 454
- Разрядность мантиссы 37
- Регуляризованные алгоритмы 121
- Рекуррентная формула 60
- Решение краевой задачи для одномерного стационарного уравнения теплопроводности 485
  - с разрывными коэффициентами 503
    - нелинейного уравнения 80
    - обыкновенного дифференциального уравнения первого порядка 411
- Робастность 78
- Сетка 419, 487, 488
  - равномерная 419
  - неравномерная 501
- Сеточные функции 419, 487
- Сдвиги по Рэлею 234
  - Уилкинсону 234
- Система линейных алгебраических уравнений плохо обусловленная 133
  - функций линейно зависима в точках 296
    - независима в точках 297
    - ортогональная на множестве точек 298
- Скалярное произведение векторов 125
- Скорость сходимости итерационного метода квадратичная 85
  - кубическая 86
  - линейная 85
- сверхлинейная 85
- Собственное значение матрицы 211
  - число матрицы 127, 212
- Собственный вектор матрицы 212
- Сплайн 333
  - интерполяционный 334
  - кубический 334
  - естественный 337
  - фундаментальный 336
  - линейный 334
  - локальный 335
  - степени  $m$  333
- Сплайна дефект 333
  - наклон 334
- Среднеквадратичное отклонение 344
- Статистический анализ ошибок 75
- Стационарная точка функции 237, 264
- Степенной метод 221
  - без сдвигов 221
  - со сдвигами 226
- Схема Горнера 58
  - единственного деления 137
  - конечно-разностная 452
  - разностная 452, 490
  - полного выбора 145
  - частичного выбора 143
  - Эйткена 322
- Сходимость итерационного метода 60
  - со скоростью геометрической прогрессии 85
    - локальная 111
    - метода аппроксимации 56
    - интерполяции 325
    - к треугольной матрице по форме 232
      - последовательности векторов по направлению 223
    - норме 125
    - по координатам 126
    - разностной схемы 496
    - с  $m$ -м порядком точности 496

- численного метода решения задачи Коши 425
- Таблица конечных разностей 311
  - разделенных разностей 318
- Теорема Вейерштрасса аппроксимационная 324
  - Гершгорина 216
  - локализации 216
  - сравнения 486, 493
  - Фабера 327
  - Чебышева 357
- Точка минимума глобального 236, 262
  - локального 236, 262
  - строгого локального 237, 263
  - стационарная 237, 264
- Точки пробные 245
  - чебышевского альтернанса 357
- Точность 26
  - абсолютная 28
  - машинная 38
  - относительная 29
  - удвоенная 41
  - ЭВМ относительная 38
- Точные методы 59
- Траектория спуска 269
- Угловой коэффициент 411
- Удвоенная точность 41
- Узлы интерполяции 295
  - кратные 304
  - квадратурной формулы 376
  - Гаусса 390
  - равноотстоящие 311
  - сетки 419, 487, 488
  - внутренние 488
  - граничные 488
- Уклонение многочлена от нуля 308
  - среднеквадратичное 344
- Унимодальная функция 239
- Упрощенный метод Ньютона 112, 205
- Уравнение диффузии одномерное 484
  - линейное однородное разностное с постоянными коэффициентами 454
  - модельное 416
  - теплопроводности одномерное стационарное 484
  - характеристическое 212, 455
  - Эйлера 507
- Усечение 29
- Условие диагонального преобладания 147, 177
  - корневое 455
  - Липшица 412, 413, 464
  - одностороннее 413, 465
  - "отсутствия узла" 337
- Условия граничные 336
  - краевые второго рода 484
  - первого рода 484
- Усовершенствованный метод Эйлера 438
- Устойчивость алгоритма 65
  - вычислительная 65
  - по входным данным 64
  - разностной схемы 494
  - решения вычислительной задачи абсолютная 48
    - относительная 48
    - по входным данным 45
    - решения задачи Коши асимптотическая 418, 466
    - на конечном отрезке по начальным значениям 416
    - и правой части 417, 465
    - по Ляпунову 418, 466
    - численного метода решения задачи Коши 422
- Форма матрицы жорданова 215
  - Хессенберга 232
- Формула Ньютона - Лейбница 375
  - парабол 381
  - рекуррентная 60
  - Эрмита 405



Формулы дифференцирования на-  
зад 480

- квадратурные 376

- кубатурные 408

- численного дифференцирова-  
ния 364

--- односторонние 371

- Филона 406

Фундаментальный кубический  
сплайн 336

Функция весовая 402

-- Лагерра 403

-- Эрмита 403

-- Якоби 403

- выпуклая 265

- овражная 276

- пробная 510

- сеточная 419, 488

- сильно выпуклая 265

- строго выпуклая 265

- унимодальная 239

- целевая 236, 262

Характеристический многочлен 455

Характеристическое уравнение 212,  
455

Хорошо обусловленная вычислитель-  
ная задача 49

Хорошо обусловленный вычисли-  
тельный алгоритм 70

Целевая функция 236, 262

Цепная дробь 362

Цифра значащая 27

-- верная 27

Числа Фибоначчи 250

Численные методы 13

Численный метод решения задачи

Коши абсолютно устойчивый 459

----- A-устойчивый 461

----- A( $\alpha$ )-устойчивый 480

----- для систем дифференциаль-  
ных уравнений первого порядка 469

-----  $h$ -шаговый 420

- - - - - линейный многошаго-  
вый 452

----- многошаговый 421

----- неявный 421

----- нуль-устойчивый 454

----- одношаговый 420

----- самостартующий 420

----- сходящийся 425

----- устойчивый 422

----- на конечном отрезке 422

----- явный 421

Число жесткости 477

- обусловленности вычислительной  
задачи 49

----- абсолютное 50

----- относительное 50

-- вычислительного алгоритма 71

- - задачи вычисления многочлена  
с приближенно заданными коэффи-  
циентами 330

-- естественное 132

-- матрицы 133

--- стандартное 133

- приближенное 25

Шаг конечно-разностный 205

- сетки 419

- спуска 268, 269

- таблицы 311

- формулы численного дифферен-  
цирования 364

Ширина ленты 131

ЭВМ 6-разрядная десятичная 42

Экономичность алгоритма 76

Экономизация степенных рядов 359

Экстраполяция 296

- Ричардсона 397

# ОГЛАВЛЕНИЕ

Предисловие .....	3
<b>Глава 1. Математическое моделирование и решение инженерных задач с применением ЭВМ .....</b>	<b>7</b>
§ 1.1. Математическое моделирование и процесс создания математической модели .....	8
§ 1.2. Основные этапы решения инженерной задачи с применением ЭВМ .....	15
§ 1.3. Вычислительный эксперимент .....	20
§ 1.4. Дополнительные замечания .....	22
<b>Глава 2. Введение в элементарную теорию погрешностей .....</b>	<b>23</b>
§ 2.1. Источники и классификация погрешностей результата численного решения задачи .....	23
§ 2.2. Приближенные числа. Абсолютная и относительная погрешности .....	24
§ 2.3. Погрешность арифметических операций над приближенными числами .....	30
§ 2.4. Погрешность функции .....	33
§ 2.5. Особенности машинной арифметики .....	35
§ 2.6. Дополнительные замечания .....	42
<b>Глава 3. Вычислительные задачи, методы и алгоритмы. Основные понятия .....</b>	<b>43</b>
§ 3.1. Корректность вычислительной задачи .....	43
§ 3.2. Обусловленность вычислительной задачи .....	49
§ 3.3. Вычислительные методы .....	55
§ 3.4. Корректность вычислительных алгоритмов .....	63
§ 3.5. Чувствительность вычислительных алгоритмов к ошибкам округления .....	67
§ 3.6. Различные подходы к анализу ошибок .....	72
§ 3.7. Требования, предъявляемые к вычислительным алгоритмам .....	76
§ 3.8. Дополнительные замечания .....	79
<b>Глава 4. Методы отыскания решений нелинейных уравнений .....</b>	<b>80</b>
§ 4.1. Постановка задачи. Основные этапы решения .....	80
§ 4.2. Обусловленность задачи вычисления корня .....	87
§ 4.3. Метод бисекции .....	91
§ 4.4. Метод простой итерации .....	93
§ 4.5. Обусловленность метода простой итерации .....	102
§ 4.6. Метод Ньютона .....	105
§ 4.7. Модификации метода Ньютона .....	112
§ 4.8. Дополнительные замечания .....	120
<b>Глава 5. Прямые методы решения систем линейных алгебраических уравнений .....</b>	<b>122</b>
§ 5.1. Постановка задачи .....	122
§ 5.2. Нормы вектора и матрицы .....	123
§ 5.3. Типы используемых матриц .....	128
§ 5.4. Обусловленность задачи решения системы линейных алгебраических уравнений .....	131
§ 5.5. Метод Гаусса .....	137
	541

§ 5.6. Метод Гаусса и решение систем уравнений с несколькими правыми частями, обращение матриц, вычисление определителей . . . . .	147
§ 5.7. Метод Гаусса и разложение матрицы на множители. <i>LU</i> -разложение . . . . .	151
§ 5.8. Метод Холецкого (метод квадратных корней) . . . . .	158
§ 5.9. Метод прогонки . . . . .	161
§ 5.10. <i>QR</i> -разложение матрицы. Методы вращений и отражений . . . . .	165
§ 5.11. Итерационное уточнение . . . . .	171
§ 5.12. Дополнительные замечания . . . . .	173
<b>Г л а в а 6. Итерационные методы решения систем линейных алгебраических уравнений . . . . .</b>	<b>174</b>
§ 6.1. Метод простой итерации . . . . .	175
§ 6.2. Метод Зейделя . . . . .	182
§ 6.3. Метод релаксации . . . . .	187
§ 6.4. Дополнительные замечания . . . . .	189
<b>Г л а в а 7. Методы отыскания решений систем нелинейных уравнений . . .</b>	<b>191</b>
§ 7.1. Постановка задачи. Основные этапы решения . . . . .	191
§ 7.2. Метод простой итерации . . . . .	196
§ 7.3. Метод Ньютона для решения систем нелинейных уравнений . . . . .	201
§ 7.4. Модификации метода Ньютона . . . . .	204
§ 7.5. О некоторых подходах к решению задач локализации и отыскания решений систем нелинейных уравнений . . . . .	207
§ 7.6. Дополнительные замечания . . . . .	210
<b>Г л а в а 8. Методы решения проблемы собственных значений . . . . .</b>	<b>211</b>
§ 8.1. Постановка задачи. Некоторые вспомогательные сведения . . . . .	211
§ 8.2. Степенной метод . . . . .	221
§ 8.3. Метод обратных итераций . . . . .	227
§ 8.4. <i>QR</i> -алгоритм . . . . .	231
§ 8.5. Дополнительные замечания . . . . .	235
<b>Г л а в а 9. Методы одномерной минимизации . . . . .</b>	<b>236</b>
§ 9.1. Задача одномерной минимизации . . . . .	236
§ 9.2. Обусловленность задачи минимизации . . . . .	242
§ 9.3. Методы прямого поиска. Оптимальный пассивный поиск. Метод деления отрезка пополам. Методы Фибоначчи и золотого сечения . . . . .	245
§ 9.4. Метод Ньютона и другие методы минимизации гладких функций . . . . .	257
§ 9.5. Дополнительные замечания . . . . .	261
<b>Г л а в а 10. Методы многомерной минимизации . . . . .</b>	<b>262</b>
§ 10.1. Задача безусловной минимизации функции многих переменных . . . . .	262
§ 10.2. Понятие о методах спуска. Покоординатный спуск . . . . .	268
§ 10.3. Градиентный метод . . . . .	272
§ 10.4. Метод Ньютона . . . . .	279
§ 10.5. Метод сопряженных градиентов . . . . .	284
§ 10.6. Методы минимизации без вычисления производных . . . . .	287
§ 10.7. Дополнительные замечания . . . . .	290
<b>Г л а в а 11. Приближение функций и смежные вопросы . . . . .</b>	<b>292</b>
§ 11.1. Постановка задачи приближения функций . . . . .	292

§ 11.2. Интерполяция обобщенными многочленами	295
§ 11.3. Полиномиальная интерполяция. Многочлен Лагранжа	300
§ 11.4. Погрешность интерполяции	302
§ 11.5. Интерполяция с кратными узлами	304
§ 11.6. Минимизация оценки погрешности интерполяции. Многочлены Чебышева	306
§ 11.7. Конечные разности	311
§ 11.8. Разделенные разности	318
§ 11.9. Интерполяционный многочлен Ньютона. Схема Эйткена	320
§ 11.10. Обсуждение глобальной полиномиальной интерполяции. Понятие о кусочно-полиномиальной интерполяции	324
§ 11.11. Интерполяция сплайнами	333
§ 11.12. Понятие о дискретном преобразовании Фурье и тригонометрической интерполяции	339
§ 11.13. Метод наименьших квадратов	343
§ 11.14. Равномерное приближение функций	356
§ 11.15. Дробно-рациональные аппроксимации и вычисление элементарных функций	361
§ 11.16. Дополнительные замечания	363
<b>Глава 12. Численное дифференцирование</b>	364
§ 12.1. Простейшие формулы численного дифференцирования	364
§ 12.2. О выводе формул численного дифференцирования	369
§ 12.3. Обусловленность формул численного дифференцирования	372
§ 12.4. Дополнительные замечания	374
<b>Глава 13. Численное интегрирование</b>	375
§ 13.1. Простейшие квадратурные формулы	375
§ 13.2. Квадратурные формулы интерполяционного типа	384
§ 13.3. Квадратурные формулы Гаусса	389
§ 13.4. Апостериорные оценки погрешности. Понятие об адаптивных процедурах численного интегрирования	392
§ 13.5. Вычисление интегралов в нерегулярных случаях	401
§ 13.6. Дополнительные замечания	408
<b>Глава 14. Численные методы решения задачи Коши для обыкновенных дифференциальных уравнений</b>	410
§ 14.1. Задача Коши для дифференциального уравнения первого порядка	411
§ 14.2. Численные методы решения задачи Коши. Основные понятия и определения	419
§ 14.3. Использование формулы Тейлора	428
§ 14.4. Метод Эйлера	430
§ 14.5. Модификации метода Эйлера второго порядка точности	435
§ 14.6. Методы Рунге-Кутты	439
§ 14.7. Линейные многошаговые методы. Методы Адамса	448
§ 14.8. Устойчивость численных методов решения задачи Коши	453
§ 14.9. Неявный метод Эйлера	461
§ 14.10. Решение задачи Коши для систем обыкновенных дифференциальных уравнений и дифференциальных уравнений $m$ -го порядка	463
§ 14.11. Жесткие задачи	472
§ 14.12. Дополнительные замечания	481
	543

Глава 15. Решение двухточечных краевых задач . . . . .	483
§ 15.1. Краевые задачи для одномерного стационарного уравнения теплопроводности . . . . .	483
§ 15.2. Метод конечных разностей: основные понятия . . . . .	487
§ 15.3. Метод конечных разностей: аппроксимации специального вида . . . . .	500
§ 15.4. Понятие о проекционных и проекционно-разностных методах. Методы Рунге и Галеркина. Метод конечных разностей . . . . .	506
§ 15.5. Метод пристрелки . . . . .	518
§ 15.6. Дополнительные замечания . . . . .	524
Литература . . . . .	525
Предметный указатель . . . . .	530

*Учебное издание*

Амосов Андрей Авериевич, Дубинский Юлий Андреевич,  
Когченко Наталья Васильевна

## ВЫЧИСЛИТЕЛЬНЫЕ МЕТОДЫ ДЛЯ ИНЖЕНЕРОВ

Редактор А.М.Суходский. Художественный редактор Т.А.Коленкова. Технические редакторы С.В.Светикова, И.А.Балелина. Корректор В.В.Кожуткина. Операторы Т.М.Дородных, В.Н.Думбар.

ИБ № 8157

ЛР № 010146 от 25.12.91. Изд. № ФМ-55. Сдано в набор 02.02.93.  
Подп. в печать 18.10.93. Формат 60×88/16. Бум. офс. № 2. Гарнитура "Таймс".  
Печать офсетная. Объем 33,32 усл.печ.л. 33,32 усл.кр.-отт. 28,15 уч.изд.л.  
Тираж 10000 экз. Заказ № 28.

Издательство "Высшая школа", 101430, Москва, ГСП-4, Неглинная ул., д. 29/14

Набрано на персональных компьютерах издательства  
Отпечатано в Московской тип. № 8 Министерства печати и массовой  
информации РФ. 101898, Москва, Хохловский пер., 7.