

С. В. МАКАРТИЧЯН, Н. С. КУЗНЕЦОВА

С. С. ДЕМЕНТЬЕВ

НЕЙРОННЫЕ СИСТЕМЫ ОБРАБОТКИ ИНФОРМАЦИИ



МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
ВОЛГОГРАДСКИЙ ГОСУДАРСТВЕННЫЙ ТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ

С. В. МАКАРТИЧЯН, Н. С. КУЗНЕЦОВА
С. С. ДЕМЕНТЬЕВ

НЕЙРОННЫЕ СИСТЕМЫ ОБРАБОТКИ ИНФОРМАЦИИ

Учебно-методическое пособие



Волгоград

УДК 004.032.26 (075)

Рецензенты:

кафедра «Теоретическая физика и волновые процессы»
Волгоградского государственного университета,
зав. кафедрой д-р физ.-мат. наук, доцент *В. А. Михайлова*;

доцент кафедры «Энергетика»
филиала Национального исследовательского университета «МЭИ»
в г. Волжском канд. техн. наук, с.н.с. *А. В. Стрижиченко*

Печатается по решению редакционно-издательского совета
Волгоградского государственного технического университета

Макартичан, С. В.

Нейронные системы обработки информации : учеб.-метод. пособие / С. В. Макартичан, Н. С. Кузнецова, С. С. Дементьев.

ISBN 978-5-9948-3914-0

Содержит необходимый теоретический материал для изучения нейронных сетей. В пособии приведены часто применяемые на практике искусственные нейронные сети, а также рассмотрены прикладные возможности нейронных сетей; уделено внимание истории развития искусственного интеллекта и этапам становления нейроинформатики.

Предназначено для студентов высших технических учебных заведений по направлению 12.04.01 «Приборостроение».

© С. В. Макартичан, Н. С. Кузнецова
С. С. Дементьев

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	4
1. ИСТОРИЯ РАЗВИТИЯ И ДВЕ ПАРАДИГМЫ РЕАЛИЗАЦИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА.....	5
2. ЭТАПЫ СТАНОВЛЕНИЯ НЕЙРОИНФОРМАТИКИ.....	8
3. СТРУКТУРА (СТРОЕНИЕ) ИНС.....	18
3.1. Нейроны и их формальные модели.....	18
3.2. Базовая и передаточная функции формального нейрона, их разновидности.....	22
3.3. Нейронный слой: определение, уравнение, разновидности, структурная схема.....	27
3.4. ИНС: определение, структурная схема, уравнение, разновидности.....	31
3.5. Преимущества нейронных сетей.....	40
4. ОБЩИЙ ПОРЯДОК СОЗДАНИЯ ИНС.....	45
4.1. Выбор архитектуры сети.....	45
4.2. Инициализация сети и предварительная обработка исходных данных.....	46
4.2.1. Инициализация ИНС: определение, функции инициализации.....	46
4.2.2. Предварительная обработка исходной информации.....	47
4.3. Настройка (обучение) ИНС.....	48
4.3.1. Настройка сети: виды, режимы и правила обучения.....	48
4.3.2. Алгоритмы обучения ИНС: общие характеристики, разновидности.....	53
4.3.3. Переобучение и недообучение ИНС, способы их преодоления.....	61
5. ЧАСТО ПРИМЕНЯЕМЫЕ НА ПРАКТИКЕ ТИПЫ ИНС.....	66
5.1. Персептроны.....	66
5.2. Линейные сети.....	68
5.3. Радиальные базисные сети.....	69
5.4. Самоорганизующиеся сети Кохонена.....	71
5.5. Рекуррентные сети.....	83
5.5.1. Сеть Элмана.....	83
5.5.2. Сеть Хопфилда.....	84
6. ПРИКЛАДНЫЕ ВОЗМОЖНОСТИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ.....	87
6.1. Нейросетевой детектор лжи.....	88
6.2. Диагностика в медицине.....	89
6.3. Обнаружение неисправностей сложных технических систем.....	91
6.4. Мониторинг аварийных режимов воздушных линий электропередачи.....	94
ЗАКЛЮЧЕНИЕ.....	106
СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ.....	107

ВВЕДЕНИЕ

Искусственные нейронные сети (ИНС) – это одно из направлений компьютерной индустрии, в основе которого лежит идея программного и аппаратного воплощения принципов организации и функционирования человеческого мозга. В последние десятилетия наблюдается взрыв интереса к нейронным сетям, они находят успешное применение в самых различных, казалось бы, не имеющих ничего общего областях, таких как промышленность, экономика, бизнес, финансы, политология, социология, криминалистика, медицина и т.д.

Отличительной особенностью нейронных сетей в сравнении с различными статистическими методами многомерного анализа является их параллелизм – способность к параллельной обработке информации и обучению, что позволяет ИНС обобщать информацию, получая обоснованный результат при оперировании данными, не встречавшимися в учебной выборке.

К числу иных уникальных качеств искусственных нейронных сетей следует отнести гибкость их структуры, возможность решения задач в условиях неопределённости, устойчивость к шумам во входных параметрах, адаптивность к изменениям внешней среды, потенциальная отказоустойчивость и т.д.

Всё перечисленное в совокупности открывает большие перспективы для построения интеллектуальных систем обработки информации в различных областях науки и техники.

Таким образом, на сегодняшний день следует констатировать наличие огромного потенциала нейронных технологий, однако их эффективное и обоснованное применение требует определённого уровня знаний и глубокого понимания принципа функционирования различных моделей нейронных сетей.

1 ИСТОРИЯ РАЗВИТИЯ И ДВЕ ПАРАДИГМЫ РЕАЛИЗАЦИИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Искусственные нейронные сети, обладая способностями к обучению, накоплению знаний и самоорганизации, способны решать широкий круг «интеллектуальных» задач, недоступных для формализации и алгоритмизации, что позволяет на современном этапе научно-технического развития отнести аппарат ИНС к одному из способов практической реализации искусственного интеллекта.

Понятие «искусственный интеллект» уходит корнями в историю Нового времени, ознаменовавшего собой становление механистической картины мира. Механистическая философия породила идею применения точных методов к анализу деятельности человека и его мышления, получившая значительное развитие в XVII-XVIII столетиях.

Идея формализации человеческого мышления нашла своё отражение в работах Томаса Гоббса (1588-1679), а в дальнейшем получила развитие в трудах Готфрида Вильгельма Лейбница (1646-1716), выделявшего небольшое количество исходных и неопределяемых понятий («алфавита»), комбинация которых согласно определённой системы правил позволяла бы, по мнению учёного, формулировать любые сложные понятия и получать «все вещи вместе с их теоретическими доказательствами» [13].

Практическим вкладом Лейбница в решение проблемы искусственного интеллекта было создание им двоичной системы счисления. Это позволило Джорджу Булю (1815-1864) сделать следующий шаг – разработать бинарную алгебру, в которой единица обозначает истину, ноль – ложь, а основными действиями являются логические операции «и», «или» [16].

Идеи Лейбница и Буля нашли своё развитие в проекте «аналитической машины» Чарльза Бэббиджа (1791-1871) – первого в мире программируемого вычислительного устройства – прообраза цифровой ЭВМ. Однако ра-

боты Бэббиджа настолько опережали технологические возможности середины XIX в., что действующая электронно-вычислительная машина с запоминаемыми программами – «ЭНИАК» – появилась лишь в 1945 г.

Ставшая впоследствии классической архитектура компьютера «ЭНИАК», основанная на последовательной обработке символов по заданной программе, получила название в честь одного из своих создателей – Джона фон Неймана (1903-1957) [22].

Не трудно заметить, что компьютеры, выполненные по схеме машины фон Неймана, по своей структуре и свойствам весьма далеки от естественного компьютера – человеческого мозга. Идея того, что машина, представляющая собой систему искусственного интеллекта, не обязана повторять биологические системы, получила название *«компьютерной»* или *«информационной» парадигмы* [20]. Одним из приверженцев подобной парадигмы являлся автор термина «искусственный интеллект» – Джон Маккарти (1927-2011). Современной реализацией информационного направления создания искусственного интеллекта является *технология экспертных систем*, получившая своё распространение с середины 70-х гг. Экспертные системы (ЭС) – это сложные программные комплексы, аккумулирующие знания специалистов в конкретных предметных областях и тиражирующие эти знания для консультаций менее квалифицированных пользователей. Знания о предметной области, необходимые для работы ЭС, определённым образом формализованы и представлены в памяти компьютера в виде базы знаний, которая может изменяться и дополняться в процессе развития системы [23].

Конкурирующим направлением разработки искусственного интеллекта выступает *квазибиологическая парадигма*, связанная с именами основоположников теории искусственных нейронных сетей, Уоррена МакКаллока (1898-1969) и Уолтера Питтса (1923-1969). Приверженцы данного течения ставят перед собой цель создания электронных устройств, струк-

турно и функционально повторяющих человеческий мозг [10]. Нейросетевая архитектура ЭВМ появилась практически одновременно с архитектурой фон Неймана и обладает целым рядом важных преимуществ: устойчивостью к помехам («живучестью»), высокой скоростью функционирования ввиду параллельной обработки информации, быстрым приспособлением к изменяющимся условиям. История развития нейроинформатики подробно рассматривается в следующей главе.

2 ЭТАПЫ СТАНОВЛЕНИЯ НЕЙРОИНФОРМАТИКИ

Мозг, будучи центральным отделом нервной системы у животных и человека, состоит из очень большого числа (порядка $10^{10} \div 10^{11}$) клеток, соединённых многочисленными связями (в среднем от 10^{14} до 10^{15} взаимосвязей). Возможность изучения строения нервных клеток появилась в 1880 г. с изобретением итальянским анатомом Камилло Гольджи (1843-1926) нового метода гистологических исследований, заключавшегося в окрашивании клеток в срезах тканей раствором нитрата серебра, что позволяло отчётливо наблюдать внутреннюю структуру отдельных клеток. Используя метод Гольджи, испанский физиолог Сантьяго Рамон-и-Кахаль (1852-1934) установил, что нервная ткань не является непрерывной структурой, образованной нервными волокнами, а состоит из отдельных составляющих – *нейронов* [11].

Нейрон – это специальная клетка (рис. 2.1), предназначенная для обработки информации. Она состоит из тела, или *сомы*, и отростков нервных волокон двух типов – *дендритов* (входов), по которым принимаются электрические импульсы, и единственного *аксона* (выхода), по которому нейрон может передавать импульс. Конец аксона разветвляется на волокна, содержащие на своих окончаниях специальные образования – *синапсы*, которые соединяются с дендритами других нейронов. Именно синапсы влияют на величину передаваемых импульсов: при прохождении импульса через синаптические окончания высвобождаются химические вещества (нейротрансмиттеры), возбуждающие или затормаживающие способность нейрона-приёмника генерировать электрические импульсы. Степень влияния синаптической связи на сигнал называют силой или *весом* синапса. Веса синапсов могут настраиваться, или *обучаться*, в зависимости от активности процессов, в которых участвуют связи. Эта зависимость от пре-

дыстории действует как память, которая, по мнению нейрофизиологов, ответственна за память человека [11].




Рис. 2.1. Взаимосвязь биологических нейронов

I ЭТАП: УСПЕХ. Идею технической реализации принципов функционирования нейронной сетей предвосхитил российский философ Павел Александрович Флоренский (1882-1937). Размышляя в своём труде «У водоразделов мысли» над предложенной Эрнстом Каппом (1808-1896) концепцией органопроекции, Флоренский отмечал: «Нервная система проецируется электрическими приборами, с которыми она имеет, по-видимому, более чем формальное сходство» [20]. Впервые же идея воспроизведения способности биологических нервных систем обучаться и исправлять ошибки, моделируя низкоуровневую структуру мозга, была предложена в вышедшей в 1943 г. статье «Логическое исчисление идей, имманентных в нервной деятельности» под авторством двух американских учёных – нейрофизиолога Уоррена Мак-Каллока и математика Уолтера Питтса. Предложенная ими модель нейрона (рис. 2.2) состояла из элементов трёх типов: умножителей (синапсов), сумматора и преобразователя. *Синапсы* осуществляют связь между нейронами и умножают входные сигналы x на числа, характеризующие силу связей – *веса* w . Сумматор Σ выполняет сложение

сигналов $w \times x$, поступающих по синаптическим связям от других нейронов, и внешних входных сигналов b . Преобразователь реализует функцию $f(s)$, где $s = \sum (w \times x) + b$ – выход сумматора. Эта функция называется функцией активации или передаточной функцией нейрона. Выход нейрона $y = f(s)$ определяется видом функции активации. Первая математическая модель нейрона использовала пороговую функцию активации и соответствовала принципу «всё или ничего» [19].

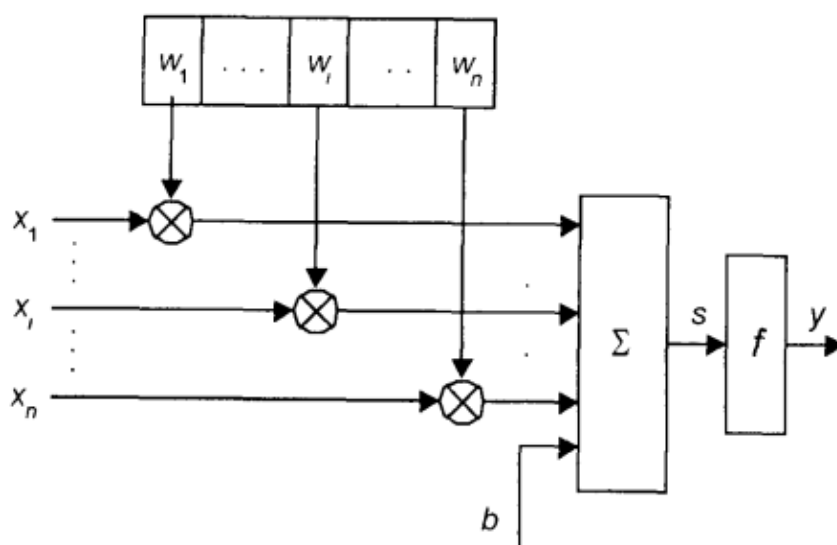


Рис. 2.2. Структура искусственного нейрона

Мак-Каллок и Питтс предложили конструкцию сети из математических нейронов – *персептрон* и показали, что такая сеть не только может выполнять числовые и логические операции, но и обладает способностью к *обучению, распознаванию образов и обобщению* – всеми теми качествами, которые свойственны интеллекту человека [23].

Первый алгоритм обучения персептрона – корректировки весовых коэффициентов сети при неправильном выходе – был предложен в 1949 г. Дональдом Хеббом (1904-1985). В общем виде схема обучения нейронной сети изображена на рис. 2.3.

Идеи Мак-Каллока и Питтса были воплощены в жизнь Фрэнком Розенблаттом (1928-1971), смоделировавшим в 1958 г. персептрон на ЭВМ

IBM-704. Спустя 2 года, в 1960 г., Розенблатт выполнил полноценную аппаратную реализацию сети, создав первый в мире нейрокомпьютер Mark I Perceptron (рис. 2.4). Используя алгоритм Хебба, Mark I удалось обучить решению сложнейшей интеллектуальной задачи – распознаванию букв латинского алфавита, нанесённых на транспаранты [22].

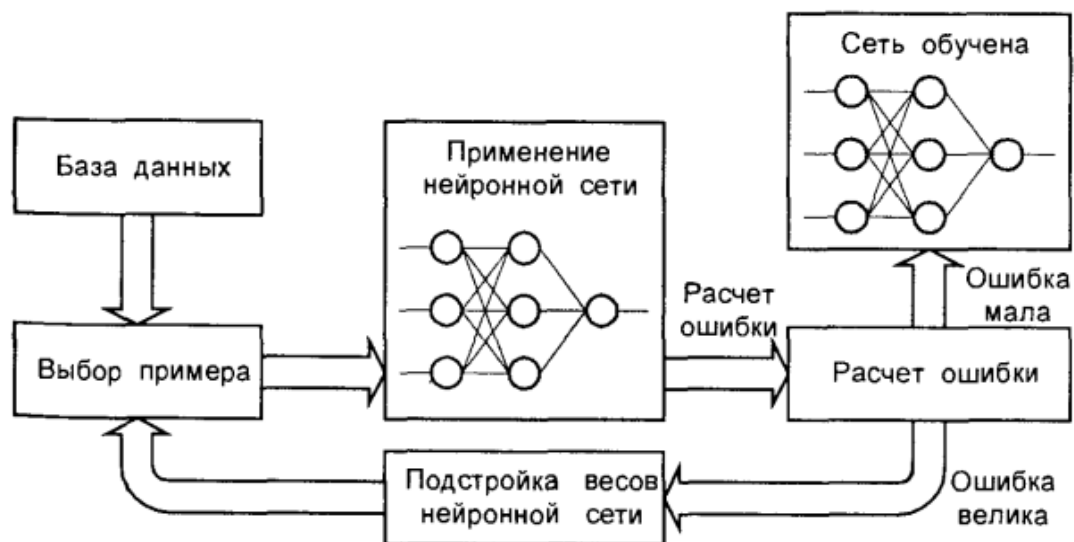


Рис. 2.3. Процесс обучения искусственной нейронной сети

а)



б)



Рис. 2.4. ЭВМ IBM-704 (а) и нейрокомпьютер Mark I Perceptron (б)

Тогда же, в 1960 г., Бернард Уидроу (род. 1929) предложил использовать в качестве функции активации нейрона непрерывную – сигмоидальную – функцию. Круг задач, решаемых подобными персептронами – *адалинами* (сети с одним выходом) и *мадалинами* (сети с несколькими выходами) – значительно расширился, т.к. благодаря непрерывности сигмоиды стала возможна оптимизация процесса обучения.

В середине 60-х гг. попытки применения искусственных нейронных сетей достигли небывалых масштабов – начиная от использования персептронов для прогнозирования погоды и курсов акций и заканчивая нейросетевым анализом электрокардиограмм для помощи врачу при диагностике заболеваний сердца. Энтузиазм того периода был настолько велик, что многие предсказывали появление «думающих» машин в самом ближайшем времени [22].

II ЭТАП: КРИЗИС. Подобные пророчества быстро сошли на нет с выходом в свет в 1969 г. книги «Персептроны», написанной Марвином Ли Минским (1927-2016) в соавторстве с южноафриканским математиком Сеймуром Пейпертом (род. 1928). В этой книге математически строго была доказана принципиальная неспособность персептронов решать многие простые задачи, получившие впоследствии название «линейно неразделимых», к которым в первую очередь относится реализация логической операции «Исключающее ИЛИ». Математические доказательства несостоятельности персептронной сети, приведённые Минским и Пайпертом, казались неопровержимыми, вследствие чего финансирование проектов в области нейрокомпьютинга прекратилось вплоть до середины 80-х гг.

III ЭТАП: ОПТИМИЗМ. В 1986 г. отдельные исследования, проводимые наиболее настойчивыми приверженцами нейросетевых технологий, дали свои плоды – с выходом в свет коллективной монографии группы учёных во главе с Дэвидом Румельхартом (1942-2011) стало ясным, что усложнение структуры нейронной сети, а именно – добавление в персеп-

тронную сеть скрытых слоёв (см. рисунок 2.5, б) – позволяет избежать той принципиальной ограниченности персептрона, о которой писал Минский, и которая, как оказалось, свойственна лишь однослойной сети (рисунок 2.5, а) [19].




Рис. 2.5 – Искусственная нейронная сеть: а – персептрон Розенблатта с J входами и I выходами; б – персептрон Румельхарта с N входами, I выходами и скрытым слоем из J нейронов

Проблема невозможности использования алгоритма Хебба для корректировки синаптических весов нейронов скрытых слоёв сети была решена Румельхартом, предложившим новый метод обучения сети – метод обратного распространения ошибки. Одновременно с Румельхартом и независимо от него этот метод был изобретён советскими учёными С.И. Барцевым и В.А. Охониным [23].

Также следует отметить период 1982-1985 гг., характерный значительным интересом научной общественности к работам физика Джона Хопфилда (род. 1933), предложившего семейство оптимизирующих нейронных сетей, моделирующих ассоциативную память [11]. Хопфилд и его многочисленные последователи обогатили теорию нейросетей многими идеями из арсенала физики, такими как *коллективные взаимодействия* нейронов, *энергия* сети, *температура* обучения и т.д. [22]

Период с конца 80-х гг. ознаменовал собой новый всплеск интереса к искусственным нейронным сетям. Активное применение аппарата ИНС в задачах прогнозирования, типичных для таких областей как экономика и

банковское дело, не могло не остаться незамеченным в России и странах СНГ – с 1991 года центры нейрокомпьютинга открываются в Москве, Киеве, Минске, Новосибирске, Санкт-Петербурге и т.д. [11]

Характерный для 2000-х гг. переход на субмикронные и нанотехнологии, а также успехи молекулярной и биомолекулярной технологий позволяют судить о появлении в ближайшем будущем принципиально новых архитектурных и технологических решений по созданию нейрокомпьютеров.

На сегодняшний день применение аппарата ИНС не требует приобретения нейрокомпьютера или нейроплаты для ПК. Аппаратная реализация искусственных нейронных сетей на сегодняшний день ещё не получила должного распространения [17]. Однако нейросетевые аппаратные решения уже внедряют в свои продукты такие известные компании, как Siemens, Intel, 3M Laboratories, Philips, IBM и т.д. В целом классификация существующих в настоящее время аппаратных нейросетевых архитектур достаточно подробно проиллюстрирована на рис. 2.6, приводимом в [10]. Внешний вид некоторых встраиваемых нейроплат изображён на рис. 2.7.




Рис. 2.6. Классификация нейросетевых архитектур по типу элементной базы



*Двухпроцессорный встраиваемый модуль
МЦ4.01*



Нейровычислитель Synapse 2



Нейроускорители IBM на шинах ISA и PCI с 16-тью нейропроцессорами ZISC036

Рис. 2.7. Встраиваемые решения на основе нейросигнальных и нейросетевых процессоров

Тем не менее гораздо чаще используются программы моделирования нейронной сети – программы-имитаторы или нейропакеты, эмулирующие для пользователя среду нейрокомпьютера на обычном компьютере. Характеристики отдельных современных нейропакетов приведены в табл. 1 [10].

Табл. 2.1. Некоторые современные нейропакеты и их характеристики

Производитель	Продукт	Платформа	Функциональные характеристики
AbTech	ModelQuest	Windows	Интегральная среда для прогнозирования, принятия решений и управления. В основу положена концепция соединения возможностей нейронных сетей и статистических методов обработки
AIWare Inc	Process Advisor	Windows	Нейропакет для решения задач упарвления динамическими процессами

Продолжение табл. 2.1

Attar Software	XpertRule Analyser	Windows	Пакет для построения моделей данных и выявления скрытых закономерностей на основе вероятностных правил, генетических алгоритмов и нейронных сетей
BioComp Systems	NeuroGenetic Optimizer	Windows	Инструментальная среда для оптимизации входных сигналов и структуры ИНС на основе генетических алгоритмов
California Scientific	BrainMaker	Windows, Mac OS	Инструментальная среда для разработки приложений на основе ИНС для распознавания образов, прогнозирования и нейросетевой памяти
Megaputer Intelligence	PolyAnalyst	Windows	Объективно-ориентированная среда для анализа данных, поиска закономерностей и представления их в символическом виде
NCS	NeuFrame	Windows	Пакет для разработки приложений на основе ИНС. Реализует комбинированные алгоритмы ИНС и нечёткой логики
NeuroDimension	NeuroSolutions	Windows, Sun	Нейропакет с широкими средствами визуализации для конструирования ИНС с произвольной топологией и процедурами обучения
NeuralWare	NeuralWorks Professional II / Plus	Mac OS, SGI, IBM RS/6000	Инструментальная среда для разработки приложений на основе 25 моделей ИНС с полным набором средств для обучения и тестирования сетей
Promised Land Technologies, Inc	Braincel	Windows	Нейропакет для моделирования ИНС прямого распространения с быстрым алгоритмом обучения
АОЗТ «Альфа Систем»	Neuro Office	Windows	Пакет для проектирования интеллектуальных программных модулей на основе ИНС с ядерной организацией

Продолжение табл. 2.1

Институт вычислительного моделирования СО РАН	NeuroPro	Windows	Нейропакет для извлечения знаний из таблиц данных
ООО «НейрОК»	Excel Neural Package	Windows	Нейропакет для статистического прогнозирования и анализа многомерных данных
НейроКомп (ВЦ СО РАН)	Глаз	Windows	Распознавание визуальных образов, используется для обработки аэрокосмической информации
	Клаб	Windows	Среда для решения задач классификации, в том числе в медицинской, психологической и технической диагностике
СНИЦ «Нейросистемы» АН Татарстана	NeuralMaker	Windows	Пакет для разработки прикладных ИНС
НПИЦ «Микросистемы»	TextAnalyst	Windows	Нейросетевая система автоматического смыслового анализа текстов
Аргусофт	Neuroline	Windows	Инструментальная среда на основе ИНС

Эмуляторы нейросетей, список которых отнюдь не ограничивается перечисленными программами, способны решать многие интересные с практической точки зрения задачи, речь о которых пойдёт далее.

3. СТРУКТУРА (СТРОЕНИЕ) ИНС

3.1. Нейроны и их формальные модели

В биологии установлено, что центральная нервная система человека или животного представляет собой множество (сеть) огромного количества нервных клеток – нейронов, которые обладают способностью передавать импульсы возбуждения друг от друга и хранить поступившую информацию. Существуют различные типы нейронов, которые отличаются размерами, геометрическими пропорциями и другими параметрами. На рис. 3.1 изображено строение одного из типов нейронов.




Рис. 3.1. Строение нейрона:

1 - тело; 2 - дендриты; 3 - аксон; 4 - концевые утолщения; 5 - ядро

Основные составные части его таковы: *сома*, или тело нейрона (1) – основная доля его массы; *дендриты* (2) – ветвящиеся отростки, воспринимающие сигналы от других нейронов, внешних раздражителей или рецепторных клеток; дендриты проводят нервные импульсы к телу нейрона и образуют основную часть его входной поверхности; *аксон* (3), или *нейрит* – отросток нейрона, проводящий нервные импульсы от тела клетки к иннервируемым органам или другим нервным клеткам; аксон разветвляется на большое число волокон с *концевыми утолщениями* (4); *ядро* (5) – обязательная часть клетки многих одноклеточных и всех многоклеточных организмов, которая управляет синтезом белков и через них всеми физиологическими процессами в клетке.

Область контакта (связи) нервных клеток (нейронов) друг с другом и с клетками исполнительных органов называют *синапсом*.

В узком смысле под *синапсом* понимают место соединения волокон аксона одного нейрона с дендритами другого. Синапсы по отношению к нейрону, на который (от которого) поступают сигналы от другого нейрона (на другой нейрон), называются *входными (выходными)*. Множество входных синапсов назовем *входной поверхностью* нейрона.

Упрощенно можно считать, что в процессе функционирования нейрон может находиться в одном из трех состояний:

- 1) *покоя*, при котором не наблюдается передача сигнала (импульса) от тела клетки к выходным синапсам;
- 2) *возбуждения*, при котором происходит генерация импульса и передача его от тела к синапсам;
- 3) *восстановления*, то есть переходного состояния между возбуждением и покоем.

Условием возбуждения нейрона, находящегося в состоянии покоя, является приход сигналов на входные синапсы, причем их суммарный (полисинаптический) уровень (потенциал), который формируется в соме, должен быть не меньше некоторого так называемого *порогового значения*, или просто *порога*. При этом происходит *возбуждение* клетки, которое характеризуется генерацией и передачей импульса по волокну аксона. Характерной особенностью процесса передачи импульса является то, что независимо от длины этот импульс не затухает, а передается от левого конца аксона до его концевых утолщений (рис. 3.1).

Биологический нейрон вырабатывает последовательность электрических импульсов, частота следования которых определяет *активность* нейрона. Под воздействием электрических импульсов изменяется потенциал сомы. Если импульсы, поступающие на синапс, приводят к повышению

(понижению) потенциала сомы, то такой синапс называется *возбуждающим (тормозящим)*.

Одной из простейших формальных моделей нейрона является следующая.

Пусть $\bar{p} = (p_1, p_2, \dots, p_R)$ – булевский вектор ($p_j \in \{0, 1\}, j = \overline{1, R}$), который описывает сигнал, поступающий на входные синапсы; его называют *вектором входа*. Наличие в какой-то момент времени во входном сигнале m единиц будем трактовать как одновременное возбуждение m синапсов на входной поверхности нейрона. Пусть выходной сигнал (обозначим его через a) – реакция нейрона на входной сигнал – определяется порогом возбудимости со значением θ , тогда сигнал 1 появится на выходе нейрона (формального) в том и только в том случае, если по крайней мере θ компонент входного сигнала равны 1. Соответствующая математическая модель нейрона описывается с помощью функции Хевисайда:

$$a = H(n) = \begin{cases} 1, n \geq 0 \\ 0, n < 0 \end{cases}. \quad (3.1)$$

где $n = \sum_{j=1}^R p_j - \theta$, то есть разность между суммарным уровнем входного сигнала и значением порога возбудимости.

Таким образом, связь между входным \bar{p} и выходным a сигналами при заданном пороге возбудимости θ описывается соотношением:

$$a = H\left(\sum_{j=1}^R p_j - \theta\right), \quad (3.2)$$

которое называют *уравнением формального нейрона*.

Предложенная модель учитывает наличие у нейрона порога возбудимости, но не отражает многих других свойств нейрона. Прежде всего, на таких нейронах нельзя промоделировать процессы, которые связаны с запоминанием информации. В этой модели возбуждение тела нейрона и мо-

мент возбуждения концевых утолщений аксона не разделяются во времени.

Обобщением рассмотренного является формальный нейрон со *взвешенным входом и смещением* (рис. 3.2).

В этой модели помимо вектора входа \bar{p} с R элементами p_1, p_2, \dots, p_R вводится *вектор весов синаптических связей* $\bar{W} = (w_1, w_2, \dots, w_R)$ – вектор, компоненты w_j которого характеризуют степень значимости элементов входного вектора p_j в формировании суммарного уровня сигнала n . Скалярное произведение $\bar{W} \cdot \bar{p} = w_1 p_1 + w_2 p_2 + \dots + w_R p_R$ называют *взвешенной суммой* входов, а устройство, которое обеспечивает ее получение, называется *сумматором* Σ . Результирующий сигнал n формируется с учетом скаляра-параметра b , который суммируется со взвешенным входом $\bar{W} \cdot \bar{p}$:

$$n = \bar{W} \cdot \bar{p} + b. \quad (3.3)$$




Рис. 3.2. Структурная схема формального нейрона со взвешенным входом и смещением

Функция f от суммарного сигнала n , значения которой определяют выходной сигнал a , получила название функции *активации (преобразования)* нейрона; $f(n)$ называют также *передаточной (пороговой)* функцией. Константа b , которая приводит к сдвигу взвешенной суммы входов как аргумента функции активации, называется *смещением* формального нейрона.

Уравнение нейрона со взвешенным входом и смещением имеет вид:

$$a = f\left(\sum_{j=1}^R w_j p_j + b\right). \quad (3.4)$$

При $b = 0$ из (3.4) получаем уравнение нейрона *без* смещения.

Если в качестве передаточной функции взять функцию Хевисайда (1.1), веса w_j всех компонент входного вектора выбрать равными единице и положить $-b$ равным порогу θ , то получим уравнение (3.2). При условии, что вход останется взвешенным произвольными числами-весами, приходим к модели, построенной Маккаллохом и Питтсом:

$$a = H\left(\sum_{j=1}^R w_j p_j - \theta\right). \quad (3.5)$$

При решении многочисленных прикладных задач из различных областей знаний в настоящее время широко применяется класс моделей типа (3.4), (3.5), хотя интенсивно развиваются так называемые импульсные модели нейронов, которые в большей степени отражают свойства биологических нейронов.

В литературе по искусственному интеллекту формальные (математические) модели биологических нейронов называют также *искусственными нейронами* (ИН). Ниже рассматриваются только искусственные нейроны, поэтому часто будем говорить просто «нейрон» или пользоваться аббревиатурой «ИН».

3.2. Базовая и передаточная функции формального нейрона, их разновидности

Внесем во входной вектор \bar{p} дополнительную координату, полагая $p_0 = 1$, то есть преобразуем его в $(R+1)$ -мерный вектор (p_0, p_1, \dots, p_R) , а смещение b будем рассматривать как дополнительную компоненту вектора весов ($w_0 = b$). Тогда соотношения (3.3), (3.4) можно записать соответственно более компактно:

$$n = \bar{W} \cdot \bar{p} + b \cdot 1 = \sum_{j=0}^R w_j p_j, \quad a = f\left(\sum_{j=0}^R w_j p_j\right). \quad (3.6)$$

Аргумент n в (3.6), стоящий под знаком функции активации f в свою очередь является функцией, причем двух векторных переменных: $\bar{W} = (w_0, w_1, \dots, w_R)$ и $\bar{p} = (p_0, p_1, \dots, p_R)$. Эту функцию обозначают через net , то есть

$$n = net(\bar{W}, \bar{p}) = \sum_{j=0}^R w_j p_j \quad (3.7)$$

и называют *базовой (сетевой) функцией* формального нейрона.

Формальные модели нейронов отличаются между собой видом сетевой и передаточной функций. Базовая функция (3.7) является *линейной* функцией координат входного вектора. При моделировании нейронов в качестве базовых применяются также *квадратичная* функция

$$net(\bar{W}, \bar{p}) = \sum_{j=0}^R w_j p_j^2, \quad (3.8)$$

и *радиальная* (сферическая) функция

$$net(\bar{W}, \bar{p}) = \frac{1}{r^2} \sum_{j=0}^R (p_j - w_j)^2, \quad (3.9)$$

где r - радиус рассматриваемой гиперсферы, и другие.

Функция активации нейрона $f(n)$, как правило, выбирается из класса сигмоидальных (S -образных) функций – непрерывных функций, имеющих две горизонтальные асимптоты и одну точку перегиба. Областью существования передаточных функций является вся числовая ось, а множество значений определяется диапазоном значений базовой функции.

Наиболее часто применяемые функции преобразования ИН представлены в табл. 3.1.

Большинство из приведенных функций преобразования ИН реализованы в виде программных продуктов семейства MATLAB.

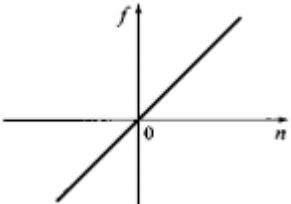
Каждая пороговая функция из таблицы 3.1 порождает целый класс функций активации, если в аналитическое представление ее ввести числовые параметры. Например, экспоненциальная функция $f(n) = e^{-n^2}$, записанная в виде $f(n) = ce^{-n^2/\sigma}$, где c, σ – константы (числовые параметры), дает семейство так называемых *гауссовых* функций.

В зависимости от того, какие выбраны базовая и пороговая функции, различают:

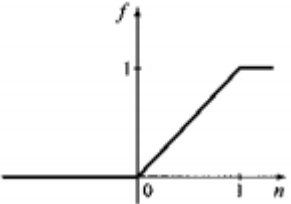
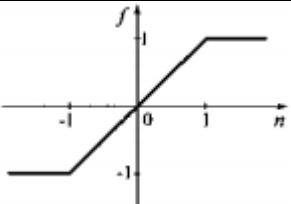
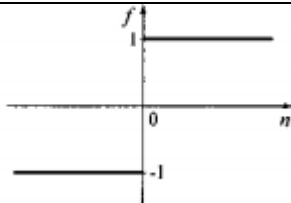
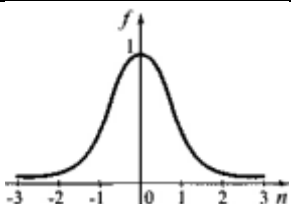
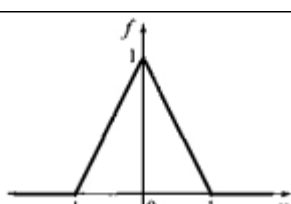
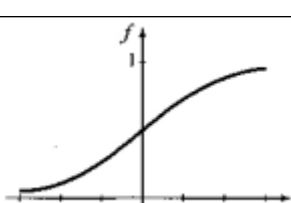
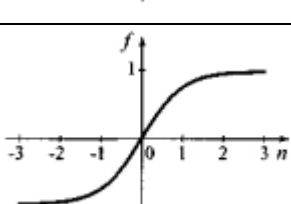
1) *линейно-пороговые* ИН - нейроны с линейной сетевой функцией (1.7) и ступенчатой или знаковой функцией активации (сигналы в таких ИН являются бинарными и принимают значения 0 или 1, либо +1 и –1);

2) *линейно-непрерывные* ИН – нейроны, базовая функция которых линейная, а передаточная функция логистическая или гиперболическая тангенциальная (сигналы в таких ИН принимают произвольные значения из диапазона $[0,1]$ или $[-1,1]$).

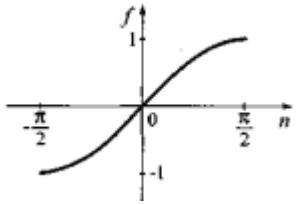
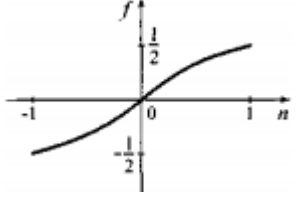
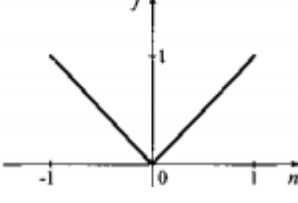
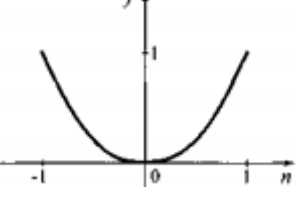
Табл. 3.1. Функции активации нейронов

Название функции	Аналитическое задание	Геометрическое изображение
1	2	3
Функция Хевисайда	$f(n) = \begin{cases} 0, n < 0 \\ 1, n \geq 0 \end{cases}$	
Линейная	$f(n) = n$	
Положительная линейная	$f(n) = \begin{cases} 0, n < 0 \\ n, n \geq 0 \end{cases}$	

Продолжение табл. 3.1

1	2	3
Линейная с ограничениями	$f(n) = \begin{cases} 0, n < 0 \\ n, 0 \leq n \leq 1 \\ 1, n > 1 \end{cases}$	
Симметричная линейная с ограничениями (шаговая)	$f(n) = \begin{cases} -1, n < -1 \\ n, -1 \leq n \leq 1 \\ 1, n > 1 \end{cases}$	
Симметричная с жесткими ограничениями (знаковая)	$f(n) = \begin{cases} -1, n < 0 \\ 1, n \geq 0 \end{cases}$	
Экспоненциальная (радиальная)	$f(n) = e^{-n^2}$	
Треугольная	$f(n) = \begin{cases} 0, n < -1 \\ 1 - n , -1 \leq n \leq 1 \\ 0, n > 1 \end{cases}$	
Логистическая	$f(n) = \frac{1}{1 + e^{-n}}$	
Гиперболическая тангенциальная	$f(n) = \frac{2}{1 + e^{-2n}} - 1$	

Продолжение табл. 3.1.

1	2	3
Синусоидальная	$f(n) = \sin n$	
Рациональная	$f(n) = \frac{n}{1+ n }$	
Модульная	$f(n) = n $	
Квадратичная	$f(n) = n^2$	

В настоящее время именно такие типы ИН чаще всего применяются в приложениях.

Из рассмотренного в п.п. 3.1, 3.2 можно сделать выводы:

1. Структура ИН такова: сумматор, который по входной информации формирует базовую функцию (n); пороговая функция, генерирующая выходной сигнал нейрона, аргументом которой является базовая функция $a=f(n)$.

2. Характеристики ИН следующие: вектор весов \bar{W} ; смещение b ; операции арифметического умножения и сложения; передаточная функция.

Как видим, входные векторы не включаются в характеристики нейрона, а функция активации рассматривается и как структурный элемент, и как характеристика ИН.

Сделанные выводы можно положить в основу определения *искусственного нейрона*: ИН – это формальная модель биологического нейрона с указанными выше структурой и характеристиками, функционирование которой описывается уравнением (3.4).

В общем случае базовая функция нейрона не обязательно должна быть линейной, то есть формироваться лишь с помощью операций умножения и сложения. Она может содержать и операции взятия модуля, и извлечения корня, возведения в квадрат.

3.3. Нейронный слой: определение, уравнение, разновидности, структурная схема

Пусть, как и выше, $\bar{p} = (p_1, p_2, \dots, p_R)$ – вектор входа. Рассмотрим совокупность S нейронов с номерами $1, 2, \dots, S$.

Множество ИН с общим вектором входа, то есть когда сигнал, соответствующий каждой компоненте входного вектора, поступает на вход всех ИН, называется *нейронным слоем с прямой передачей сигнала (с прямыми связями)*.

Геометрическое представление слоя дано на рис. 3.3.




Рис. 3.3. Нейронный слой с прямыми связями

Его можно истолковать как ориентированный граф, если жирные точки и кружочки, которыми обозначены нейроны, рассматривать как вершины графа, а дугами считать направленные отрезки. Дуге, идущей от компоненты p_j к ИН с номером i , где $i = \overline{1, S}$, приписывается вес w_{ij} .

Матрица W размера $S \times R$, элементами которой являются веса w_{ij} , называется *матрицей весов связей (весовой матрицей)*:

$$W = (w_{ij})_{S \times R} = \begin{pmatrix} w_{11} & w_{12} & \dots & w_{1R} \\ w_{21} & w_{22} & \dots & w_{2R} \\ \dots & \dots & \dots & \dots \\ w_{S1} & w_{S2} & \dots & w_{SR} \end{pmatrix} = \begin{pmatrix} \bar{w}_1 \\ \bar{w}_2 \\ \dots \\ \bar{w}_S \end{pmatrix}. \quad (3.10)$$

Номер строки i (столбца j) указывает на номер нейрона (компоненты входа). Каждая строка матрицы W – вектор $\bar{w}_i = (w_{i1}, w_{i2}, \dots, w_{iR})$; $i = \overline{1, S}$ – называется *вектором весов i -го нейрона*.

Поскольку каждый ИН порождает свой выходной сигнал a_i , то слой формирует вектор-столбец $a = (a_1, a_2, \dots, a_S)^T$, который называют *вектором выхода* нейронного слоя (T – символ транспонирования).

По аналогии с (1.4) можно записать *уравнение нейронного слоя*:

$$\bar{a} = \bar{f}(\bar{n}) = \bar{f}(W \cdot \bar{p} + \bar{b}), \quad (3.11)$$

где \bar{a} – вектор выхода слоя; $\bar{f} = (f_1, f_2, \dots, f_S)$ – вектор-функция преобразования нейронов, f_i – функция активации i -го нейрона; W – матрица весов связей размера $S \times R$; \bar{p} – вектор входа; $\bar{b} = (b_1, b_2, \dots, b_S)$ – вектор смещений, b_i – смещение i -го ИН; $\bar{n} = (n_1, n_2, \dots, n_S)$ – вектор базовых функций, n_i – базовая функция i -го нейрона; $\bar{a}, \bar{b}, \bar{n}, \bar{f}$ – векторы размера $S \times 1$, а \bar{p} имеет размер $R \times 1$.

Описание слоя в виде (1.11) равносильно системе уравнений

$$a_i = f_i(n_i), \quad i = \overline{1, S}, \quad (3.12)$$

где базовая функция i -го ИН n_i имеет вид:

$$n_i = \text{net}_i(\bar{w}_i, \bar{p}) = \text{net}_i\left(\sum_{j=1}^R w_{ij} p_j\right), \quad i = \overline{1, S}. \quad (3.13)$$

Замечания.

1. Нейронный слой можно интерпретировать (истолковать) как параллельное соединение ИН.

2. Количество входов R в слое и число нейронов S не обязательно должны совпадать; при $S=1$ нейронный слой вырождается в ИН.

3. На практике в каждом ИН слоя используется одна и та же функция активации ($f_i = f$), однако можно создавать слои нейронов с различными передаточными функциями.

4. Нейронный слой *характеризуется* матрицей весов W , смещением \bar{b} , операциями умножения $W \cdot \bar{p}$, суммирования и функцией активации f ; вектор входов \bar{p} обычно не включается в характеристики слоя. *Структура* (строение) слоя следует из его определения.

5. Другой разновидностью нейронного слоя, кроме рассмотренного слоя с прямыми связями, является *рекуррентный* нейронный слой, или слой с *обратными связями*, – это когда вместе с сигналами p_j ($j=1 \dots R$), на входы ИН, составляющих слой, подаются выходные сигналы a_i ($i=1 \dots S$).

Представление слоя графом (см. рис. 3.3) не отражает строение каждого нейрона и слоя в целом, поэтому для их изображения применяют структурные схемы, к описанию которых мы и перейдем.

Если в графе слоя (см. рис. 3.3) вершины-кружки заменить структурной схемой ИН (см. рис 3.2), то в результате получим схему, которая называется *развернутой структурной схемой* нейронного слоя (рис. 3.4, а).

Если изображать все составляющие-нейроны слоя, то при большом числе ИН развернутая структурная схема выглядит довольно громоздко. Поэтому слой представляют, как показано на рис. 1.4, б: вход слоя изобра-

жают в виде темной вертикальной черты, под которой указывают число элементов входа R ; наносят символы векторов $\bar{a}, \bar{b}, \bar{n}, \bar{p}$, матрицы весов W , указывая ниже их размеры, а также константу 1, которая рассматривается как элемент входа; отображают стрелками связи между входом \bar{p} и матрицей весов W , между 1 и вектором смещений \bar{b} и др.; кружком со знаком $+$ внутри подчеркивают, что входом \bar{n} функции активации \bar{f} служит сумма смещения \bar{b} и произведения $W \cdot \bar{p}$.

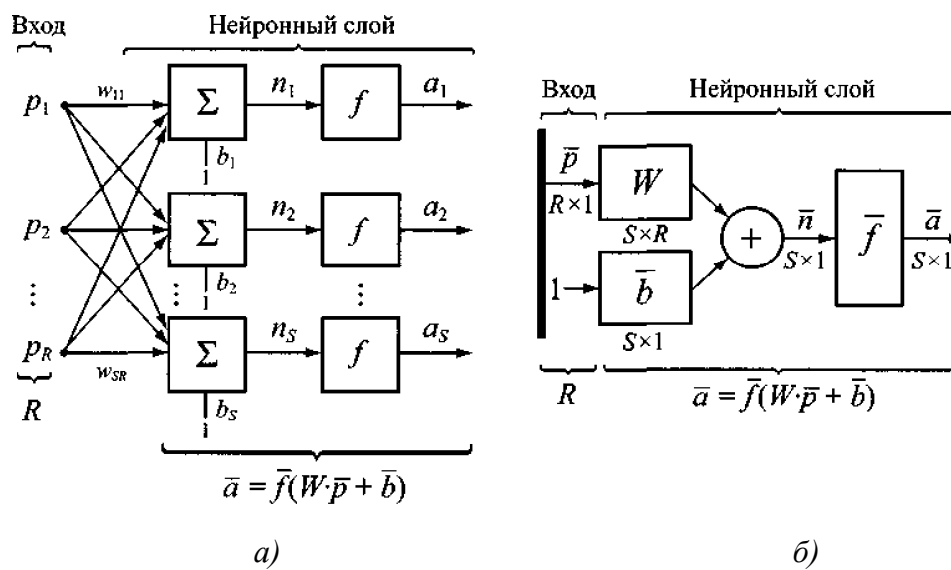


Рис. 3.4. Структурная схема нейронного слоя: а) развернутая; б) укрупненная

Структурная схема (см. рис. 3.4, б), полученная на основании приведенного описания, называется *укрупненной структурной схемой* нейронного слоя.

На укрупненной структурной схеме для обозначения типа функции активации используются специальные графические символы. Например, широко применяемые ступенчатая, знаковая, логистическая, гиперболическая тангенциальная функции (см. табл. 3.1), изображаются так, как показано на рис. 3.5.




Рис. 3.5. Графические символы обозначения функций активации: *a)* ступенчатой; *б)* знаковой; *в)* логистической; *г)* гиперболической тангенциальной

В этих символах не трудно усмотреть уменьшенные и стилизованные графики соответствующих функций (см. табл. 3.1). Над собственно символами указано название функции в системе MATLAB.

3.4. ИНС: определение, структурная схема, уравнение, разновидности

ИНС с прямой передачей сигналов. Биологические нейронные сети - объекты, составленные, как правило, из очень большого числа нейронов. Они служат механизмом обработки информации в нервной системе, поясняющим во многих ситуациях поведение или реакцию живых организмов. Аналогично под ИНС следует понимать объект, состоящий из большого числа взаимосвязанных искусственных нейронов. Полагаем, что читатель интуитивно уже догадался, что подобно тому, как отдельные ИН являются элементами нейронного слоя, нейронные слои представляют собой составные части ИНС – блоки («кирпичики»), из которых строится сеть. В дальнейшем изучаются только искусственные нейронные сети, поэтому для краткости изложения будем говорить просто «сеть», «нейронная сеть» или использовать аббревиатуру «ИНС».

Дадим строгое определение сети, введя предварительно некоторые вспомогательные понятия.

Рассмотрим совокупность M нейронных слоев с прямыми связями, занумерованных в естественном порядке: 1, 2,..., k ,..., M . Тот из двух слоев,

который имеет меньший (большой) номер, называется *предшествующим* (*последующим*) по отношению к другому слою. В случае, когда номер предшествующего слоя на единицу меньше номера последующего слоя, его называют *предыдущим*.

Чтобы различать характеристики слоев используемые ранее символы снабжают верхним индексом – номером слоя. Например, W^k , \bar{a}^k обозначают соответственно матрицу связей, вектор выхода k -го слоя.

Если взвешенный вход последующего слоя формируется на основании выходного вектора предыдущего слоя, то говорят, что слои *охвачены прямой связью* (*прямой передачей сигнала*).

Если выходные сигналы последующего слоя участвуют в формировании взвешенного входа предыдущего слоя, то говорят, что слои *охвачены обратной связью* (*обратной передачей сигнала*).

Схематическое изображение прямой и обратной связей двух соседних - предыдущего и последующего - слоев дано на рис. 1.6, где слои представлены прямоугольниками.




Рис. 3.6. Прямая и обратная связи между соседними слоями

Множество, состоящее из M ($M \geq 2$) взаимосвязанных слоев, называется *M-слойной ИНС с прямой передачей сигналов (с прямыми связями)*, если оно удовлетворяет условиям:

- 1) существует единственный слой, который не является последующим по отношению ко всем остальным слоям (*первый слой*);
- 2) существует единственный слой, который не является предыдущим по отношению ко всем остальным слоям (*выходной слой*);

3) каждая пара соседних слоев охвачена прямой связью.

Все слои ИНС, кроме выходного слоя, называются *скрытыми* (*внутренними, промежуточными*) слоями. Чтобы подчеркнуть, что сеть содержит M слоев, будем пользоваться аббревиатурой «ИНС- M ».

В зависимости от количества слоев различают двухслойные сети (ИНС-2), трехслойные (ИНС-3) и так далее, которые объединяются общим термином – *многослойные сети*. Естественно, один нейронный слой как множество взаимосвязанных нейронов называют *однослойной сетью* (ИНС-1). ИНС-1 не имеет скрытых слоев.

На рис. 3.7 приведена блок-схема ИНС- M в которой, не нарушая общности, номера слоев сети выбраны в соответствии с их нумерацией в естественном порядке, от 1 до M .




Рис. 3.7. Многослойная искусственная нейронная сеть с прямой передачей сигналов

Выход M -го слоя помечен равенством $\bar{a}^M = \bar{a}$ для того, чтобы подчеркнуть, что выход этого слоя является *выходом сети* \bar{a} .

Если на рис. 3.7 каждый блок – нейронный слой – заменить его структурной схемой (развернутой или укрупненной), то получим *структурную схему сети*. Укрупненная структурная схема ИНС-2 изображена на рис. 3.8.

С целью выработки умения читать схемы ИНС рекомендуем внимательно изучить эту сеть.

Анализируя ее (сопоставлением изображения каждого слоя с рис. 3.4, б), заключаем:

1) входной вектор \bar{p}^1 – двумерный, первый (скрытый) слой содержит 4 нейрона, \bar{b}^1 имеет, соответственно, размер 4×1 , а матрица весов W^1 размера 4×2 ; следовательно, базовая функция \bar{n}^1 и \bar{a}^1 – выход первого слоя – четырехэлементные векторы;

2) входным вектором второго слоя является вектор \bar{a}^1 , слой содержит 3 нейрона; этими сведениями определяются размеры вектора смещения \bar{b}^2 , матрицы весов W^2 , базовой функции \bar{n}^2 и вектора выхода сети $\bar{a}^2 = a$.




Рис. 3.8. Увеличенная структурная схема ИНС-2

Поскольку для всех ИН каждого слоя берется одна и та же функция активации, то все компоненты векторов \bar{f}^1 , \bar{f}^2 равны между собой; их тип обозначается специальным графическим символом (см. рис. 3.5).

Уравнения каждого из слоев:

$$\bar{a}^1 = \bar{f}^1(\bar{n}^1), \quad \bar{a}^2 = \bar{f}^2(\bar{n}^2), \quad (3.14)$$

где $\bar{n}^1 = W^1 \bar{p}^1 + \bar{b}^1$, $\bar{n}^2 = W^2 \bar{p}^2 + \bar{b}^2$ – базовые (сетевые) функции слоев, позволяют дать аналитическое описание – уравнение – всей сети:

$$\bar{a} = \bar{a}^2 = \bar{f}^2(W^2 \cdot \bar{f}^1(W^1 \bar{p}^1 + \bar{b}^1) + \bar{b}^2), \quad (3.15)$$

которое, как видно, содержит суперпозицию (наложение) функций \bar{f}^1 , \bar{f}^2 .

В общем случае, для многослойной сети (ИНС-М),

$$\bar{a} = \bar{f}^1 \circ \bar{f}^2 \circ \dots \circ \bar{f}^M, \quad (3.16)$$

где \circ - символ суперпозиции.

Понятно, что уравнение однослойной сети совпадает с уравнением нейронного слоя (3.11), одной из характеристик которого является весовая матрица W . В многослойной ИНС каждый скрытый слой характеризуют двумя весовыми матрицами: матрицей весов для сигналов, поступающих на вход слоя, которую называют просто *весами входа слоя*; матрицей весов для сигналов, исходящих из слоя, которую называют *весами выхода слоя*.

В двухслойной сети один скрытый слой - первый, он характеризуется весами входа W^1 и весами выхода W^2 . Отметим, что веса выхода предыдущего слоя являются весами входа последующего слоя, а выходной слой сети, как и обособленный слой, имеет только входные веса.

Рекуррентные сети. Наряду с сетями с прямой передачей сигналов рассматриваются более сложные по своему строению и более богатые по функциональным возможностям ИНС.

Если в ИНС-1 с прямой передачей сигнала нейронный слой имеет обратные связи, то такая сеть называется *рекуррентной*, или ИНС-1 с *обратными связями*. Обратные связи, действующие в пределах одного слоя, называют *латеральными* (*lateral* - горизонтальный).

ИНС-М с прямой передачей сигналов, в которой два или более слоев охвачены обратной связью, называются *рекуррентной*, или ИНС-М с *обратными связями*. Многослойную рекуррентную сеть с наличием латеральных связей называют *комбинированной* ИНС-М.

Статические и динамические ИНС. Пусть имеется последовательность m входных векторов. Будем говорить, что вход ИНС *статический* (*неподвижный*), если входная информация – сигналы – подается на сеть в виде последовательности уже сформированных заранее векторов входа, которые обрабатываются ИНС одновременно (от формирования взвешенного входа до получения выходного вектора). ИНС со

статическим входом носит соответствующее название - *статическая* ИНС. Работа такой ИНС равносильна одновременному функционированию m одинаковых сетей, на каждую из которых подавался бы один из векторов входа и генерировался один из выходов.

Пусть теперь имеется последовательность m отдельных сигналов (импульсов), не являющихся векторами входа. Будем говорить, что вход ИНС *динамический* (подвижный), если входная информация подается на сеть в виде последовательности объектов, не являющихся входными векторами, на основании которой ИНС создает по некоторому правилу последовательно («пошагово») входные векторы, формирует взвешенный вход и генерирует выход. Сеть с динамическим входом носит одноименное название - *динамическая ИНС*. Составные части динамических сетей, которые обеспечивают формирование входных векторов, называются *линиями* (*элементами*) *задержки* (*запаздывания*).

Для лучшего понимания сути статических и динамических сетей рассмотрим конкретный пример. Построим наипростейшие статическую и динамическую сети ИНС-1, состоящие из одного нейрона с прямыми связями и линейной функцией активации $f(n)=n$ – линейного нейрона (рис. 3.9, а, б).




Рис. 3.9. ИНС-1 с линейной функцией активации: а) статическая; б) динамическая

Как видно из рис. 3.9, а, у статической сети векторы входа и весов двухэлементные: $\bar{p} = (p_1, p_2)^T$, $\bar{W} = (w_{11}, w_{12})$, а значит, сетевая функция имеет вид $\bar{n} = \bar{W} \cdot \bar{p} + \bar{b} = w_{11}p_1 + w_{12}p_2 + b$ и одновременно дает выход сети (согласно выбранной функции активации). Присваиваем значения весов и смещения: $\bar{W} = (1, 2)$, $b=0$ (нейрон без смещения). Сеть готова к работе, так как определились все ее характеристики-параметры.

Пусть на сеть подается последовательность из трех векторов входа:

$$\bar{p}_1 = \begin{pmatrix} p_{11} \\ p_{21} \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \end{pmatrix}, \bar{p}_2 = \begin{pmatrix} p_{12} \\ p_{22} \end{pmatrix} = \begin{pmatrix} -1 \\ 0,5 \end{pmatrix}, \bar{p}_3 = \begin{pmatrix} p_{13} \\ p_{23} \end{pmatrix} = \begin{pmatrix} 2 \\ 0,5 \end{pmatrix},$$

тогда соответствующие выходы таковы:

$$a_1 = \bar{W} \cdot \bar{p}_1 = (1 \ 2) \begin{pmatrix} 1 \\ 0 \end{pmatrix} = 1, a_2 = \bar{W} \cdot \bar{p}_2 = (1 \ 2) \begin{pmatrix} -1 \\ 0,5 \end{pmatrix} = 0,$$

$$a_3 = \bar{W} \cdot \bar{p}_3 = (1 \ 2) \begin{pmatrix} 2 \\ 0,5 \end{pmatrix} = 3.$$

Статическая сеть обрабатывает сразу все векторы и выдает результат в виде трехкомпонентного вектора $\bar{a} = (a_1, a_2, a_3) = (1 \ 0 \ 3)$. Объясняется это тем, что векторы \bar{p}_1 , \bar{p}_2 , \bar{p}_3 можно рассматривать как два трехэлементных вектора:

$$\bar{q}_1 = (p_{11}, p_{12}, p_{13}), \bar{q}_2 = (p_{21}, p_{22}, p_{23})$$

и тогда их взвешенная сумма даст вектор \bar{a} :

$$\begin{aligned} w_{11}\bar{q}_1 + w_{12}\bar{q}_2 &= w_{11}(p_{11}, p_{12}, p_{13}) + w_{12}(p_{21}, p_{22}, p_{23}) = \\ &= (w_{11}p_{11}, w_{11}p_{12}, w_{11}p_{13}) + (w_{12}p_{21}, w_{12}p_{22}, w_{12}p_{23}) = (a_1, a_2, a_3) = \bar{a}. \end{aligned}$$

То есть сеть взвешивает одновременно все первые и все вторые координаты заданных векторов входа, а потом находит сумму полученных трехмерных векторов и выдает вектор \bar{a} .

Динамическая сеть (рис. 3.9, б) так действовать не может, так как для нее входная информация представляется объектами, которые не являются

входными векторами. Для обеспечения возможности формировать векторы входа статическую сеть дополняют элементом задержки D (*delay - задержка*), который характеризуется *вектором задержки* $\bar{\theta} = (\theta_1, \theta_2, \dots, \theta_N)$. Значения его компонент определяют выбор правила формирования входных векторов. Возвращаясь к примеру, положим $\bar{\theta} = (\theta_1, \theta_2) = (0 \ 1)$, а последовательность входных сигналов, из которых будут формироваться входные векторы, выберем такой:

$$p(1) = -1, p(2) = -0,5, p(3) = 0,5, p(4) = 1.$$

Координаты входных векторов p_1, p_2 рассматриваются как функции параметра t – абстрактного времени – с учетом вектора задержки:

$$\bar{p} = \begin{pmatrix} p_1 \\ p_2 \end{pmatrix} = \begin{pmatrix} p_{\theta_1}(t) \\ p_{\theta_2}(t) \end{pmatrix} = \begin{pmatrix} p(t - \theta_1) \\ p(t - \theta_2) \end{pmatrix}.$$

В нашем случае $\theta_1 = 0, \theta_2 = 1$, значит

$$p_1(t) = p(t), p_2(t) = p(t-1), \quad (3.17)$$

где $t = 0, 1, 2, 3, 4$ – моменты абстрактного времени. Соотношения (3.17) определяют правило построения входных векторов. Для $t = 0$ – начального момента времени – обычно полагают $p(0)=0$.

Придавая t значения 1, 2, 3, 4, получаем последовательность входных векторов:

$$\begin{pmatrix} p(1) \\ p(0) \end{pmatrix} = \begin{pmatrix} -1 \\ 0 \end{pmatrix}, \begin{pmatrix} p(2) \\ p(1) \end{pmatrix} = \begin{pmatrix} -0,5 \\ -1 \end{pmatrix}, \begin{pmatrix} p(3) \\ p(2) \end{pmatrix} = \begin{pmatrix} 0,5 \\ -0,5 \end{pmatrix}, \begin{pmatrix} p(4) \\ p(3) \end{pmatrix} = \begin{pmatrix} 1 \\ 0,5 \end{pmatrix}.$$

Базовая функция, а у нас и выход, формируются согласно уравнению:

$$\bar{a} = n(t) = \bar{W} \cdot \bar{p}(t) = w_{11}p(t) + w_{12}p(t-1) \text{ (см. рис. 1.9, б).}$$

В результате работы сеть сгенерирует выход

$$\bar{a} = (a_1, a_2, a_3, a_4) = (-1, -2,5, -0,5, 2).$$

Действительно:

$$(1 \ 2) \begin{pmatrix} -1 \\ 0 \end{pmatrix} = -1, \quad (1 \ 2) \begin{pmatrix} -0,5 \\ -1 \end{pmatrix} = -2,5, \quad (1 \ 2) \begin{pmatrix} 0,5 \\ -0,5 \end{pmatrix} = -0,5, \quad (1 \ 2) \begin{pmatrix} 1 \\ 0,5 \end{pmatrix} = 2.$$

При изменении порядка следования элементов во входной последовательности будут изменяться значения на выходе.

Подводя итоги вышеизложенного, отметим, что в отличие от биологических нейронных сетей – реально существующих объектов, ИНС является вычислительной схемой (процедурой), которая по заданной (входной) числовой информации (обычно это числовые массивы) формирует выходные массивы чисел.

Задача отыскания выходного массива чисел по заданной ИНС и входному массиву чисел, которую можно назвать *прямой задачей* сетей, решается довольно просто. Гораздо более сложная задача, которую можно отнести к категории обратных задач, формулируется так: по заданному входному массиву чисел найти такую ИНС, чтобы соответствующий выходной массив чисел удовлетворял тем или иным условиям. Именно задачи такого рода и представляют интерес в различных областях знаний.

ИНС как математическая модель, «грубо» подражающая «живой» сети дает возможность, тем не менее, решать довольно сложные задачи, не поддающиеся традиционным методам; и это несмотря на то, что формирование базовых функций требует всего лишь двух арифметических операций сложения и умножения. Самыми «мощными» элементами ИНС являются, пожалуй, функции активации, суперпозиция которых (в многослойных сетях) дает возможность описывать сложнейшие явления и процессы.

Удивительным является именно то, что математическая база ИНС весьма проста по сравнению с математическим аппаратом, который используют многие традиционные методы.

3.5. Преимущества нейронных сетей

Совершенно очевидно, что свою силу нейронные сети черпают, во-первых, из распараллеливания обработки информации и, во-вторых, из способности самообучаться, т.е. создавать обобщения. Под термином *обобщение* понимается способность получать обоснованный результат на основании данных, которые не встречались в процессе обучения. Эти свойства позволяют нейронным сетям решать сложные задачи, которые на сегодняшний день считаются трудноразрешимыми. Однако на практике при автономной работе нейронные сети не могут обеспечить готовые решения. Их необходимо интегрировать в сложные системы. В частности, комплексную задачу можно *разбить* на последовательность относительно простых, часть из которых может решаться нейронными сетями. Очень важно уяснить, что для создания компьютерной архитектуры, которая будет способна имитировать человеческий мозг (если такое окажется возможным вообще), придется пройти долгий и трудный путь.

Использование нейронных сетей обеспечивает следующие полезные свойства систем.

1. *Нелинейность*. Искусственные нейроны могут быть линейными и нелинейными. Нейронные сети, построенные из соединений нелинейных нейронов, сами являются нелинейными. Более того, эта нелинейность особого сорта, так как она *распределена* по сети. Нелинейность является чрезвычайно важным свойством, особенно если сам физический механизм, отвечающий за формирование входного сигнала, тоже является нелинейным (например, человеческая речь).

2. *Отображение входной информации в выходную*. Одной из популярных парадигм обучения является *обучение с учителем*. Это подразумевает изменение синаптических весов на основе набора маркированных учебных *примеров*. Каждый пример состоит из входного сигнала и соот-

ветствующего ему *желаемого отклика*. Из этого множества случайным образом выбирается пример, а нейронная сеть модифицирует синаптические веса для минимизации расхождений желаемого выходного сигнала и формируемого сетью согласно выбранному статистическому критерию. При этом собственно модифицируются *свободные параметры* сети. Ранее использованные примеры могут впоследствии быть применены снова, но уже в другом порядке. Это обучение проводится до тех пор, пока изменения синаптических весов не станут незначительными. Таким образом, нейронная сеть обучается на примерах, составляя таблицу соответствий вход-выход для конкретной задачи. Такой подход заставляет вспомнить *непараметрическое статистическое обучение*. Это направление статистики имеет дело с оценками, не связанными с какой-либо конкретной моделью, или, с биологической точки зрения, с обучением с нуля. Здесь термин “непараметрический” используется для акцентирования того, что изначально не существует никакой предопределенной статистической модели входных данных. Для примера рассмотрим задачу *классификации образов*. В ней требуется соотнести входной сигнал, представляющий физический объект, или событие, с некоторой предопределенной категорией. При непараметрическом подходе к этой задаче требуется “оценить” рамки решения в пространстве входного сигнала на основе набора примеров. При этом не используется никакая вероятностная модель распределения. Аналогичный подход применяется и в парадигме обучения с учителем. Это еще раз подчеркивает параллель между отображением входных сигналов в выходные, осуществляемым нейронной сетью, и непараметрическим статистическим обучением.

3. *Адаптивность*. Нейронные сети обладают способностью *адаптировать* свои синаптические веса к изменениям окружающей среды. В частности, нейронные сети, обученные действовать в определенной среде, могут быть легко переучены для работы в условиях незначительных коле-

баний параметров среды. Более того, для работы в *нестационарной* среде (где статистика изменяется с течением времени) могут быть созданы нейронные сети, изменяющие синаптические веса в реальном времени. Естественная для классификации образов, обработки сигналов и задач управления архитектура нейронных сетей может быть объединена с их способностью к адаптации, что приведет к созданию моделей адаптивной классификации образов, адаптивной обработки сигналов и адаптивного управления. Известно, что чем выше адаптивные способности системы, тем более устойчивой будет ее работа в нестационарной среде. При этом хотелось бы заметить, что адаптивность не всегда ведет к устойчивости; иногда она приводит к совершенно противоположному результату. Например, адаптивная система с параметрами, быстро изменяющимися во времени, может также быстро реагировать и на посторонние возбуждения, что вызовет потерю производительности. Для того чтобы использовать все достоинства адаптивности, основные параметры системы должны быть достаточно стабильными, чтобы можно было не учитывать внешние помехи, и достаточно гибкими, чтобы обеспечить реакцию на существенные изменения среды. Эта задача обычно называется *дилеммой стабильности-пластичности*.

4. *Очевидность ответа*. В контексте задачи классификации образов можно разработать нейронную сеть, собирающую информацию не только для определения конкретного класса, но и для увеличения *достоверности* принимаемого решения. Впоследствии эта информация может использоваться для исключения сомнительных решений, что повысит продуктивность нейронной сети.

5. *Контекстная информация*. Знания представляются в самой структуре нейронной сети с помощью ее состояния активации. Каждый нейрон сети потенциально может быть подвержен влиянию всех остальных ее ней-

ронов. Как следствие, существование нейронной сети непосредственно связано с контекстной информацией.

6. *Отказоустойчивость*. Нейронные сети, облаченные в форму электроники, потенциально отказоустойчивы. Это значит, что при неблагоприятных условиях их производительность падает незначительно. Например, если поврежден какой-то нейрон или его связи, извлечение запомненной информации затрудняется. Однако, принимая в расчет распределенный характер хранения информации в нейронной сети, можно утверждать, что только серьезные повреждения структуры нейронной сети существенно повлияют на ее работоспособность. Поэтому снижение качества работы нейронной сети происходит медленно. Незначительное повреждение структуры никогда не вызывает катастрофических последствий. Это очевидное преимущество робастных вычислений, однако его часто не принимают в расчет. Чтобы гарантировать отказоустойчивость работы нейронной сети, в алгоритмы обучения нужно закладывать соответствующие поправки.

7. *Масштабируемость*. Параллельная структура нейронных сетей потенциально ускоряет решение некоторых задач и обеспечивает *масштабируемость* нейронных сетей в рамках технологии VLSI (very-large-scale-integrated). Одним из преимуществ технологий VLSI является возможность представить достаточно сложное поведение с помощью иерархической структуры.

8. *Единообразие анализа и проектирования*. Нейронные сети являются универсальным механизмом обработки информации. Это означает, что одно и то же проектное решение нейронной сети может использоваться во многих предметных областях. Это свойство проявляется несколькими способами.

а) Нейроны в той или иной форме являются стандартными составными частями *любой* нейронной сети.

б) Эта общность позволяет использовать одни и те же теории и алгоритмы обучения в различных нейросетевых приложениях.

в) Модульные сети могут быть построены на основе интеграции целых модулей.

9. *Аналогия с нейробиологией (Neurobiological analogy).* Строение нейронных сетей определяется аналогией с человеческим мозгом, который является живым доказательством того, что отказоустойчивые параллельные вычисления не только физически реализуемы, но и являются быстрым и мощным инструментом решения задач. Нейробиологи рассматривают искусственные нейронные сети как средство моделирования физических явлений. С другой стороны, инженеры постоянно пытаются почерпнуть у нейробиологов новые идеи, выходящие за рамки традиционных электросхем.

4. ОБЩИЙ ПОРЯДОК СОЗДАНИЯ ИНС

4.1. Выбор архитектуры сети

Под *архитектурой* ИНС понимают сведения о структурных элементах сети и взаимосвязях между ними, то есть информацию о числе слоев в сети; количестве нейронов в каждом слое; наличии или отсутствии смещений и линий задержки; виде функции активации в каждом слое; характере соединения слоев между собой (прямая связь, обратная связь, с линиями задержки или без них).

Выбор конфигурации сети зависит от типа задачи, которую должна решить ИНС (аппроксимация функций, распознавание образов, классификация объектов и другие), и ее сложности. Например, двухслойная ИНС (см. рис. 1.8) без обратных связей, со смещениями, нейроны скрытого слоя которой содержат сигмоидальные пороговые функции, а выходной слой с линейной функцией активации используется для аппроксимации функций. Если задать достаточное число нейронов в слоях, то ИНС с такой архитектурой может с высокой точностью воспроизвести любую функцию с конечным числом точек разрыва. Конкретная задача определяет также размеры векторов входа $\bar{p} \ (R \times 1)$ и выхода $\bar{a} = \bar{a}^M \ (S^M \times 1)$.

При формировании архитектуры ИНС следует учитывать, что возможности сети (относительно генерации решений достаточно сложных задач) значительно возрастают с увеличением слоев и (или) числа нейронов в каждом слое.

Практические рекомендации по выбору архитектуры для часто применяемых сетей к сожалению, в большинстве случаев они носят эвристический характер.

В вычислительной модели ИНС информация об архитектуре сводится к заданию массивов, которые характеризуют параметры сети, связанные с ее конфигурацией в целом и с отдельными составными частями.

4.2. Инициализация сети и предварительная обработка исходных данных

4.2.1. Инициализация ИНС: определение, функции инициализации

Пусть, исходя из тех или иных соображений, конфигурация сети выбрана. Следующий шаг в построении ИНС – это ее *инициализация* – задание начальных значений весов и смещений.

Инициализация сети осуществляется с помощью одноименных функций – *функций инициализации*, каждая из которых имеет свое имя и присваивает те или иные начальные значения элементам матриц весов и компонентам вектора смещения каждого слоя. Например, можно задать: нулевые значения весов и смещений; элементы столбцов матрицы весов как среднее арифметическое наименьшего и наибольшего значений из диапазона (отрезка) изменения элементов вектора входа; случайные веса и смещения; случайные матрицы весов с нормированными столбцами или строками; равные, отличные от нуля, компоненты вектора смещений.

Функции инициализации могут задаваться одними и теми же для всей сети или разными для каждого отдельного слоя. Общих рекомендаций по инициализации ИНС, которые бы способствовали сокращению времени подбора (подгона) нужных весов и смещений, пока нет, однако выработаны некоторые эвристические правила. Например, для сетей без обратных связей с линейными функциями активации веса обычно инициализируются случайными значениями из отрезка $[-1,1]$; для сетей же, использующих сигмоидальные функции активации, такой подход не рекомендуется.

4.2.2. Предварительная обработка исходной информации

Функционирование ИНС связано с проведением больших объемов вычислений с данными, диапазоны изменения которых могут существенно различаться и которые имеют случайные разбросы, обусловленные погрешностью их измерения или задания.

Предварительная обработка данных направлена на то, чтобы обеспечить достоверность вычислений, повышение их точности и, в конечном счете - эффективность функционирования создаваемой ИНС. Одной из причин предпринимаемых мер, которые описаны ниже, является то, что компьютеры имеют ограниченный диапазон представления чисел и ограниченную точность выполнения операций умножения и сложения в арифметике с плавающей точкой.

Масштабирование векторов входа – это взаимно однозначное отображение промежутка значений их координат $[p_{min}, p_{max}]$, где p_{min} (p_{max}) наименьшая (наибольшая) координата входных векторов, на определенный диапазон значений, приемлемый для компьютера. В большинстве случаев данные приводятся к промежутку $[-1, 1]$. Если наряду с векторами входа задаются и соответствующие цели, то с ними поступают аналогично. В результате выполнения масштабирования векторов входов выходные векторы сети будут также масштабированы. Для осуществления масштабирования входной информации и восстановления истинных значений координат выходных векторов созданы соответствующие функции.

Нормировка векторов входов и целей, которые распределены по нормальному закону, – это приведение их к случайным векторам, имеющим среднее значение (математическое ожидание), равное 0, и стандартное отклонение, равное 1. Для нормировки таких входных векторов и векторов целей, а также для восстановления истинных значений элементов выход-

ных векторов в математическом обеспечении ИНС имеется соответствующие функции.

Факторный анализ векторов входа – это: ортогонализация входных векторов, что исключает их взаимную корреляцию; упорядочение векторов так, чтобы первыми (главными компонентами) были векторы, охватывающие большой диапазон значений; удаление векторов, диапазон значений которых незначителен (по сравнению с главными компонентами). Математическое обеспечение ИНС содержит специальную программу выделения главных компонент.

4.3. Настройка (обучение) ИНС

4.3.1. Настройка сети: виды, режимы и правила обучения

Пусть выбрана архитектура сети и произведена ее инициализация. Следующий шаг в создании ИНС, самый трудный и ответственный, – *настройка сети*, под которой понимают процесс целенаправленного изменения начальных значений весов и смещений таким образом, чтобы выходной вектор ИНС давал (с той или иной степенью точности) решение поставленной задачи. По-другому, более коротко, говорят так: *настройка (обучение)* сети – это процесс подбора (подгонки) параметров математической модели изучаемого явления или процесса, которая реализуется нейронной сетью.

Различают три вида обучения ИНС.

Обучение с учителем. Пусть задана последовательность $\bar{p}(\mu)$, $\mu = 1, \dots, Q$ входных векторов $\bar{p}(\mu) = (p_1(\mu), p_2(\mu), \dots, p_R(\mu))$ и известна соответствующая (желаемая) последовательность векторов выхода $\bar{t}(\mu) = (t_1(\mu), t_2(\mu), \dots, t_R(\mu))$, которые называют *векторами цели (целями)*.

Множество пар $(\bar{p}(\mu), \bar{t}(\mu))$, то есть

$$\{(\bar{p}(1), \bar{t}(1)), (\bar{p}(2), \bar{t}(2)), \dots, (\bar{p}(Q), \bar{t}(Q))\}, \quad (4.1)$$

называют *обучающим множеством*.

Суть обучения с учителем состоит в следующем:

1) после инициализации ИНС на ее вход подаются векторы $\bar{p}(\mu)$, сеть генерирует выход $\bar{a}(\mu)$ и находит разность между вектором цели $\bar{t}(\mu)$ и полученным на выходе вектором $\bar{a}(\mu)$, которую называют *ошибкой обучения*;

2) веса и смещения сети изменяются так, чтобы выходные векторы приближались к желаемым, то есть, чтобы уменьшалась ошибка обучения.

Тот и иной способ изменения параметров сети называют *правилом настройки* ИНС.

Цель обучения состоит в том, чтобы ИНС после настройки смогла генерировать правильные ответы на входные векторы, которые не принадлежат обучающему множеству.

Обучение без учителя – это настройка ИНС на решение той или иной задачи в случаях, когда исследователь располагает входными векторами, а целевые выходы в явном виде не задаются. Это означает, что в отличие от обучения с учителем для изменения весов и смещений нет возможности воспользоваться ошибкой обучения; ИНС должна самообучаться, обнаруживая закономерности во входной информации. Поэтому сети, настроенные без учителя, часто называют *самоорганизующимися сетями*. Существуют правила, по которым осуществляется самообучение ИНС. Одно из них – правило Хебба – основывается на одноименной гипотезе: если выходной сигнал одного нейрона возбуждает другой нейрон, и это постоянно повторяется, то все связи между этими нейронами увеличиваются. Другими словами, в биологических нейронах веса синаптических связей изменяются пропорционально корреляции между активностями нейронов. Формально правилу Хебба соответствует соотношение

$$\Delta w_{ij} = \eta a_i x_j, \quad (4.2)$$

где a_i – выходной сигнал i -го нейрона; x_j – входной сигнал j -го нейрона, который формируется j -м нейроном; η – числовой параметр, который называют *коэффициентом обучения* (удачный выбор которого сокращает время процесса настройки).

В соответствии с (2.2) изменение веса связи не требует привлечения сведений о желаемой реакции нейрона, что позволяет сети самообучаться.

Существуют различные модификации правила Хебба.

Смешанное обучение ИНС – это когда веса и смещения одних нейронов устанавливаются посредством обучения с учителем, а остальных – на основе самообучения.

Немаловажным для обучения ИНС является вопрос о том, насколько мощным должно быть обучающее множество. Согласно одному из эвристических правил число обучающих векторов (при обучении без учителя), пар векторов (при обучении с учителем) должно быть в 10 раз больше числа связей в сети. При этом, естественно, надо учитывать сложность решаемой задачи: если отображение вход-выход гипотетически линейное (нелинейное), то мощность обучающего множества может быть и меньше (больше). Практика обучения ИНС показывает, что для большинства задач достаточно нескольких сотен или тысяч пар $(\bar{p}(\mu), \bar{t}(\mu))$. Редко встречаются задачи, для решения которых с достаточно высокой точностью настройку ИНС можно произвести обучающим множеством с мощностью $Q < 100$.

Формальную оценку уровня (степени) обучения ИНС дают с помощью *функции ошибок* – функции, по значениям которой судят о том, насколько хорошо настроена сеть на решение поставленной задачи. Функ-

цию ошибок называют также *критерием качества* обучения сети. Чаще всего применяются следующие критерии качества:

1) сумма квадратов отклонений (невязок, ошибок)

$$I = \sum_{i=1}^N e_i^2; \quad (4.3)$$

2) средняя квадратическая ошибка

$$I = \frac{1}{N} \sum_{i=1}^N e_i^2; \quad (4.4)$$

3) комбинированная ошибка

$$I = \frac{\gamma}{N} \sum_{i=1}^N e_i^2 + \frac{1-\gamma}{n} \sum_{j=1}^n x_j^2; \quad (4.5)$$

4) средняя абсолютная ошибка

$$I = \frac{1}{N} \sum_{i=1}^N |e_i|, \quad (4.6)$$

где $N=S^M$ – число координат векторов выхода \bar{a} и цели \bar{t} ; $e_i = t_i - a_i$ – отклонение i -го элемента выхода от i -го элемента цели; γ – так называемый параметр регуляризации $\gamma \in (0,1)$; n – общее число настраиваемых параметров сети (весов и смещений); $x_j - j$ -я координата вектора настраиваемых параметров, который объединяет в себе веса и смещения сети.

Значения весов и смещений ИНС, которые обеспечивали бы как можно меньшую ошибку решения задачи, отыскивают путем минимизации функций вида (2.3)-(2.6) с учетом всех элементов обучающего множества. В зависимости от того, каким образом элементы обучающего множества учитываются для корректировки весов и смещений, различают два режима настройки сети. Если обновление параметров ИНС осуществляется при поступлении в сеть *каждого* очередного вектора входа (*всех* векторов) обучающего множества, то такой режим настройки ИНС называют *последовательным* (блочным, или групповым).

Согласно этим режимам настройки приобретают соответствующий вид функций ошибок. Например, согласно (4.3), при блочном подходе минимизации подлежит функция:

$$I = \sum_{q=1}^Q \sum_{i=1}^N (e_i^q)^2, \quad (4.7)$$

где Q – мощность обучающего множества; q – индекс, соответствующий номеру обучающего элемента.

Вообще говоря, и в частности, из соотношения (4.7) следует, что по существу обучение ИНС сводится к задаче отыскания глобального минимума функций многих переменных. При создании сетей с линейными функциями активации можно построить алгоритм, гарантирующий достижение абсолютного минимума функции ошибки. Для сетей с нелинейными пороговыми функциями в общем случае нельзя гарантировать достижения глобального минимума функции ошибок, так как многомерная поверхность может иметь локальные минимумы, плоские участки (плато), седловые точки и длинные узкие овраги.

Замечания.

1. Относительно обучающего множества говорят, что оно должно быть *репрезентативным*, то есть таким, чтобы содержать в себе достаточно для настройки сети «образцов» входной (и выходной) информации, и эта информация отображала бы, по возможности, характер решаемой впоследствии задачи. Тогда можно надеяться на то, что подобные параметры сети будут пригодными для моделирования других задач. Способность сети, обученной на некотором множестве данных, выдавать правильные результаты для достаточно широкого класса новых данных, не представленных при обучении, называют *свойством обобщения* ИНС.

2. Последовательный и блочный подходы к настройке статических ИНС применяются как при обучении с учителем, так и при обучении без

учителя. Динамические сети обучаются только в последовательном режиме.

3. Для минимизации функции ошибок (при обучении с учителем) применяются традиционные алгоритмы поиска глобального экстремума функции многих переменных и алгоритмы, разработанные с учетом специфики нейронных сетей.

4.3.2. Алгоритмы обучения ИНС: общие характеристики, разновидности

Напомним, что методы (и соответствующие им алгоритмы) отыскания экстремума функции многих переменных делятся на три категории – методы нулевого, первого и второго порядка.

Под методами *нулевого порядка (прямыми методами)* понимают методы, которые используют только информацию о значениях функции ошибок в заданных точках.

Методами *первого порядка (градиентными методами)* называются методы отыскания экстремума функции ошибок с использованием градиента функционала качества обучения. В отличие от методов нулевого порядка они дают возможность определить стратегию перехода от точки к точке с целью уменьшения ошибки обучения. Направление кратчайшего спуска к минимуму соответствует антиградиенту функции ошибок. Последовательность выбора параметров сети описывается соотношением:

$$\bar{x}_{k+1} = \bar{x}_k - \alpha_k \bar{g}_k, \quad (4.8)$$

где \bar{x}_k , \bar{g}_k – векторы параметров, градиент функционала соответственно на k -м шаге; α_k – параметр скорости обучения; \bar{x}_{k+1} – вектор параметров сети на $(k+1)$ -м шаге.

Последовательность таких шагов при удачном выборе α_k приведет к значениям настраиваемых параметров, которые обеспечат минимум функ-

ционала. При большом значении есть опасность «перепрыгнуть» через минимум или «уйти» в неправильном направлении. Малые α_k дают верные направления движения к минимуму, но при этом понадобится очень много итераций. Значение параметра α_k определяется обычно опытным путем, оно уменьшается по мере приближения к минимуму. Модификацией описанного, градиентного, метода, является метод сопряженного градиента, в котором направление последующего шага сопряжено с предыдущим:

$$\bar{x}_{k+1} = \bar{x}_k - \alpha_k \bar{p}_k, \quad (4.9)$$

где $\bar{p}_k = -\bar{g}_k + \beta_k \bar{p}_{k-1}$, $\bar{p}_0 = -\bar{g}_0$ – направление движения на k -м шаге; \bar{g}_k – градиент функции ошибок; β_k – числовой параметр k -й итерации.

Методами *второго порядка* называются методы отыскания экстремума функции ошибок, которые используют вторые частные производные функции ошибок. Классическим методом второго порядка является метод Ньютона, в котором

$$\bar{x}_{k+1} = \bar{x}_k - H_k^{-1} \bar{g}_k, \quad (4.10)$$

где H_k^{-1} – матрица, обратная к матрице H_k вторых частных производных функции ошибок на k -м шаге.

Более быструю сходимость к минимуму дают, вообще говоря, методы второго порядка, однако они требуют больших затрат из-за вычисления H_k – матрицы Гесса (гессиана). Разработаны так называемые *квазиньютоновы* методы, в которых гессианы заменяются некоторыми их приближениями: методы секущих плоскостей и Левенберга-Марквардта.

Методы отыскания экстремума функции многих переменных и их модификации порождают соответствующие *алгоритмы настройки* нейронных сетей, которые работают итеративно. Каждая итерация от подачи обучающего множества на вход сети до обновления параметров ИНС называется *эпохой (циклом)* настройки.

При обучении с учителем каждая эпоха требует: подачи на вход сети всех элементов обучающего множества (последовательно или блочно); вычисления выходных значений сети; сравнения значений выхода с целевыми значениями; вычисления значений критерия качества обучения, его градиента и, возможно, гессиана.

После корректировки значений весов и смещений все действия повторяются. Процесс настройки сети прекращается, если прошло определенное, заранее намеченное, число циклов или когда ошибка перестала уменьшаться (или достигла некоторого наперед заданного значения).

При обучении без учителя сравнение значений выхода с целями не производится.

Каждый алгоритм настройки дает вместе с тем и правило обучения сети. Если, например, используются алгоритмы, порождаемые методами первого порядка, то изменение параметров сети происходит в направлении, так или иначе связанном с направлением антиградиента функции ошибок. В простейшем случае приращение некоторого веса (или смещения) прямо пропорционально соответствующей частной производной функции ошибок I :

$$\bar{x}_{k+1} = \bar{x}_k - \alpha_k \bar{g}_k \Rightarrow \Delta \bar{x}_k = -\alpha_k \bar{g}_k \Rightarrow \Delta \bar{x}_k^i = -\alpha_k \frac{\partial I}{\partial x_k^i}, \quad (4.11)$$

где $\Delta \bar{x}_k$ – приращение вектора параметров на k -м шаге; $\Delta \bar{x}_k^i$ – значение i -й координаты вектора приращений; $\partial I / \partial x_k^i$ – частная производная функции ошибок по i -той координате на k -м шаге, $i = 1, 2, \dots, n$; n – число всех параметров сети.

Остановимся теперь на одном из методов оптимизации (минимизации) функции ошибки как функции многих переменных, которые учитывают специфику критерия качества ИНС – *методе обратного распространения ошибки*. По существу это специальный случай градиентного

метода, в котором частные производные функции ошибок (а значит, и ее градиент) вычисляются по параметрам сети.

Рассмотрим простейший случай функционала типа (4.7) при условии, что $Q = 1$, то есть когда через сеть прогоняется один образец:

$$I = \frac{1}{2} \sum_{r=1}^{S^M} e_r^2 = \frac{1}{2} \sum_{r=1}^{S^M} (t_r - a_r^M)^2, \quad (4.12)$$

где множитель $1/2$, который не влияет на координаты точки минимума, взят для удобства выкладок; S^M – число нейронов входного слоя; r – индекс суммирования, взятый в (4.7) вместо i ; t_r – r -й элемент вектора цели; a_r^M – r -й элемент выхода слоя M .

Выберем линейную пороговую функцию $f(n) = n$, тогда

$$a_r^M = \sum_{l=0}^{S^{M-1}} w_{rl}^M a_l^{M-1}, \quad (4.13)$$

а производная a_r^M по параметру w_{ij}^M имеет вид:

$$\frac{\partial a_r^M}{\partial w_{ij}^M} = \begin{cases} 0, & r \neq i \\ a_j^{M-1}, & r = i \end{cases}, \quad (4.14)$$

где w_{ij}^M – вес связи между нейроном i -го слоя M и j -м нейроном слоя $M-1$.

С учетом (2.14) для частной производной I по параметру w_{ij}^M получим:

$$\frac{\partial I}{\partial w_{ij}^M} = \sum_{r=1}^{S^M} (t_r - a_r^M) \frac{\partial a_r^M}{\partial w_{ij}^M} = \sum_{i=1}^{S^M} (t_i - a_i^M) a_j^{M-1}. \quad (4.15)$$

Обозначим первый множитель правой части в (4.15) через δ_i^M , то есть положим

$$\delta_i^M = \sum_{i=1}^{S^M} (t_i - a_i^M). \quad (4.16)$$

Тогда

$$\frac{\partial I}{\partial w_{ij}^M} = \delta_i^M a_j^{M-1}. \quad (4.17)$$

где величину δ_i^M называют *ошибкой выхода* i -го нейрона слоя M ; a_j^{M-1} – выходной сигнал j -го нейрона $(M-1)$ -го слоя и, в то же время, входной сигнал для слоя M .

Для любых двух последовательных слоев $k-1, k$ аналогично получаем:

$$\frac{\partial I}{\partial w_{ij}^k} = \delta_i^k a_j^{k-1}, \quad (4.18)$$

где $k = M, M-1, \dots, 2, 1$ (перебор берется в обратном порядке); $a_j^0 = p_j$ – j -я координата выходного вектора.

Соотношение (2.18) дает возможность вычислить градиент критерия качества по весам слоев сети, причем ошибки выхода каждого предшествующего слоя по отношению к выходному слою M будут выражаться через ошибки выхода последующих слоев. Именно этим обстоятельством и объясняется словосочетание «обратное распространение ошибки».

Метод минимизации функции ошибок, основанный на вычислении ее градиента по параметрам сети, называют *методом обратного распространения ошибок*; порождаемый им алгоритм имеет одноименное название.

Согласно (4.8) с учетом (4.18) получаем соответствующее правило обучения ИНС:

$$\Delta w_{ij}^k = \eta \delta_i^k a_j^{k-1}, \quad (4.19)$$

где η – параметр скорости настройки, которое называется *дельта-правилом* и читается так: изменение (приращение) веса связи Δw_{ij}^k между j -м нейроном предыдущего слоя $(k-1)$ и i -м нейроном последующего слоя (k) прямо пропорционально произведению ошибки на выходе i -го нейрона (δ_i^k) на

его входной сигнал (a_j^{k-1}) формируемый нейроном j . Опуская в (4.19) верхние индексы, правило представляют в виде (рис. 4.1):

$$\Delta w_{ij} = \eta \delta_i^{\text{вых}} a_j^{\text{вх}}. \quad (4.20)$$

Описанный алгоритм требует обучения с учителем и дифференцируемости пороговых функций. Существует несколько вариантов алгоритма обратного распространения ошибки; они могут использоваться самостоятельно и в сочетании с другими стратегиями оптимизации.




Рис. 4.1. Схема к дельта-правилу обучения ИНС

Перечислим далее алгоритмы, которые задействованы в системе MATLAB, указывая их соответствующие названия и сокращенные англоязычные обозначения, ассоциирующиеся с названиями.

Градиентные алгоритмы обучения

Алгоритм GD, или алгоритм градиентного спуска, обеспечивающий движение по поверхности функции ошибок в направлении, противоположном ее градиенту. При этом параметр скорости остается неизменным.

Алгоритм GDM, или алгоритм градиентного спуска с возмущением, предназначен для обучения сетей с прямой передачей сигнала. Он позволяет преодолевать локальные неровности поверхности критерия качества, то есть не останавливаться в локальных минимумах. Параметр скорости настройки постоянен.

Алгоритм GDA, или алгоритм градиентного спуска с выбором параметра скорости настройки, использующий эвристическую стратегию изменения этого параметра в процессе настройки сети.

Алгоритм Rprop, или пороговый алгоритм обратного распространения ошибки, с переменным параметром скорости настройки, реализующий, как и алгоритм *GDA*, эвристическую стратегию изменения шага приращения параметров для многослойных нейронных сетей.

Алгоритмы метода сопряженного градиента

Согласно (4.9) вектор параметров сети $\bar{x}_{k+1} = \bar{x}_k - \alpha_k \bar{p}_k$ в методе сопряженного градиента содержит два параметра: α_k – параметр скорости обучения, β_k – числовой параметр k -й итерации. Алгоритмы метода сопряженного градиента различаются способом вычисления константы β_k .

Алгоритм CGF, реализующий так называемый метод Флетчера–Ривса, использует β_k в виде:

$$\beta_k = \frac{\bar{g}_k^T \bar{g}_k}{\bar{g}_{k-1}^T \bar{g}_{k-1}}, \quad (4.21)$$

то есть как отношение квадрата нормы градиента на текущей итерации к квадрату нормы градиента на предыдущей итерации (T – символ транспонирования вектора-градиента функции ошибок).

Алгоритм CGP – это алгоритм Полака–Рибейры, в котором константа выбирается так:

$$\beta_k = \frac{\Delta \bar{g}_k^T \bar{g}_k}{\bar{g}_{k-1}^T \bar{g}_{k-1}}, \quad (4.22)$$

то есть как отношение скалярного произведения приращения градиента на текущей итерации на текущий градиент к квадрату нормы градиента на предыдущей итерации. По сравнению с *CGF* этот алгоритм требует несколько большей памяти.

Алгоритм CGB – это алгоритм Биеле и Пауэлла, который реализует стратегию рестарта: периодическое переустановка по направлению антиградиента направления, которое устанавливает метод сопряженного градиента. Рестарты улучшают сходимость алгоритма; они выполняются, если текущее и предыдущее направления градиентов слабоортогональны, что определяется условием:

$$\bar{g}_{k-1}^T \bar{g}_k \geq 0,2 \|\bar{g}_k\|^2, \quad (4.23)$$

то есть текущий и предыдущий градиенты слабоортогональны, если их скалярное произведение не меньше пятой части квадрата длины текущего градиента. Алгоритм *CGB* обеспечивает, как правило, лучшую сходимость по сравнению с *CGP*, но требует большей оперативной памяти.

Алгоритм SCG - это алгоритм Моллера, который содержит в себе элементы методов оптимизации второго порядка с целью обеспечить уменьшение ошибки после каждой итерации алгоритма. Основой его являются идеи метода сопряженного градиента.

Квазиньютоновы алгоритмы обучения

Названные алгоритмы являются альтернативой методам сопряженного градиента для ускоренного обучения сетей. Их основой служит метод Ньютона. Однако вычисление гессиана – весьма сложная и дорогостоящая в вычислительном отношении процедура. Поэтому разработаны алгоритмы, не требующие вычисления вторых производных: на каждой итерации они используют некоторую оценку матрицы Гессе.

Алгоритм BFGS, разработанный несколькими авторами, сходится на меньшем числе итераций, чем алгоритмы сопряженного градиента, но требует большего количества вычислений на каждой итерации и большего объема памяти. Он, как правило, эффективен для настройки сетей с небольшим числом слоев, для сетей больших размеров лучше использовать алгоритм *Rprop*.

Алгоритм OSS, или одношаговый алгоритм метода секущих плоскостей, разработанный Баттити. Он объединяет идеи метода сопряженного градиента и метода Ньютона, причем новое направление выбирается без вычисления обратной матрицы H^{-1} , поэтому требует меньших объемов оперативной памяти и вычислительных ресурсов на эпоху по сравнению с *BFGS*.

Алгоритм LM, или алгоритм Левенберга–Маквардта, использует аппроксимацию гессиана с помощью метода обратного распространения ошибки, что существенно проще вычисления матрицы Гессе. Главный недостаток в том, что он требует памяти для хранения матриц больших размеров, но зато обеспечивает уменьшение ошибки после каждой итерации. Как показывает практика применения различных алгоритмов обучения, этот алгоритм является самым быстродействующим и пригоден для настройки нейронных сетей с несколькими сотнями параметров (весов и смещений).

Замечание. При решении той или иной конкретной задачи трудно определить, какой алгоритм будет самым быстрым. В общем плане рекомендуют начинать с алгоритма *LM*. Если это потребует слишком много памяти, то следует перейти к алгоритму *BFG* или одному из алгоритмов метода сопряженного градиента. Алгоритм *Rprop* также характеризуется высоким быстродействием и предъявляет относительно небольшие требования к объему используемой памяти.

4.3.3. Переобучение и недообучение ИНС, способы их преодоления

Пусть исследователем, исходя из тех или иных соображений, выбраны *атрибуты* ИНС:

- 1) архитектура сети;
- 2) инициализация и предварительная обработка данных (обучающего множества);

- 3) вид обучения (с учителем, без учителя, смешанный);
- 4) режим настройки (последовательный или блочный);
- 5) критерий качества (функция ошибок);
- 6) алгоритм настройки;
- 7) правило обучения.

Можно начинать обучение ИНС. Прогоняем (пропускаем) через сеть обучающее множество и замечаем, что по истечении n_0 эпох (циклов) ошибка обучения $E_{об}$ (например, среднеквадратическое отклонение от цели) становится меньше E_{max} – заданного, максимально допустимого, значения ошибки: $E_{об} < E_{max}$. Обучение закончено. Но если взять еще один образец–пример, не участвующий в обучении, то может оказаться, что ошибка проверки $E_{пр}$, как и $E_{об}$, вначале уменьшается, до n^* циклов, а потом начинает возрастать (рис. 4.2, а). В этом случае говорят, что имеет место *переобучение сети*.

Если обе ошибки – обучения и проверки – уменьшаются с увеличением числа эпох, но остаются относительно большими, то говорят, что *сеть недообучена* (см. рис. 4.2, б).




Рис. 4.2. Явления переобучения (а) и недообучения (б) сети

К основным причинам переобучения и недообучения сети относятся:

- 1) неудачный выбор архитектуры;
- 2) нерепрезентативность обучающего множества.

В первом случае для преодоления рассматриваемых эффектов рекомендуют, проводя вычислительный эксперимент, изменить количество слоев в ИНС и/или число нейронов в них: уменьшить при переобучении и увеличить при недообучении (или говорят – соответственно уменьшить, увеличить *мощность сети*). Конечно, априори практически невозможно предсказать, насколько мощной должна быть сеть для конкретного приложения.

Преодоление «нехороших» явлений можно осуществить с помощью критерия качества – функционала (4.5), который состоит из среднеквадратической ошибки и так называемой *штрафной функции*, оцениваемой суммой квадратов весов и смещений. Такой функционал всегда имеет минимум, и положение этого минимума непрерывно зависит от параметра регуляризации γ . При значении γ , близком к единице, большие значения параметров сети штрафуются: второе слагаемое в (4.5) будет малым из-за близкой к нулю разности $1-\gamma$. Основная трудность реализации такого подхода – *метода регуляризации* – состоит в оптимальном выборе значения параметра регуляризации. Правда, существует алгоритм, позволяющий автоматически установить значение γ . Он основан на использовании статистических методов, реализован в MATLAB.

Во втором случае (см. выше) *формируют представительное обучающее множество*. Это делается так: из исходных данных выделяют три множества, первое из которых *обучающее (тренировочное)*, второе – *контрольное (проверочное)*, третье – *тестовое*; тренировочное множество образцов используется для настройки параметров сети; проверочным подмножеством контролируется представительность используемого множества.

Когда ошибка для контрольного подмножества начинает увеличиваться (см. рис. 4.2, *a*), это означает, что в сети начал проявляться эффект переобучения. В этом случае фиксируется n^* , на которой ошибка для контрольного подмножества была минимальной, и восстанавливаются соответствующие значения настраиваемых параметров. Соответствующая мощность обучающего множества признается представительной.

Подготовленная таким образом сеть затем тестируется: если ИНС обучена, то тестовое множество должно давать минимум ошибки при том же числе итераций, что и контрольное множество. Тестовое множество используется только один раз, иначе оно превращается в контрольное множество. Способ преодоления переобучения, основанный на использовании контрольного множества, называют *процедурой прерывания обучения*.

Процедура прерывания обучения позволяет построить сеть, обладающую свойством обобщения.

Замечания

1. При практической настройке ИНС приходится экспериментировать с большим числом сетей различных конфигураций, обучая каждую из них несколько раз и сравнивая полученные результаты. Главным критерием выбора сети является контрольная погрешность – погрешность, которую дает проверочное множество. При этом руководствуются правилом: из двух нейронных сетей с приблизительно равными контрольными погрешностями выбирают ту, которая проще по своей архитектуре.

2. При обучении с учителем для оценки качества работы ИНС проводят *регрессионный анализ* векторов выхода и целей в координатах цель–выход, то есть при фиксированном значении цели подсчитывается математическое ожидание выхода. Если выходы точно равняются целям, то угловой коэффициент линии регрессии должен быть равен 1, а сдвиг ее вдоль оси выходов равен 0. При высоком качестве работы ИНС названные величины должны быть близкими соответственно к единице и нулю. Регресси-

онный анализ проводится, как правило, для сетей, построенных на основе процедуры прерывания обучения. В MATLAB для этих целей имеется специальная функция.

3. На основании изложенного материала, согласно перечисленным атрибутам ИНС, приводим структурную схему построения нейронных сетей (рис. 2.3), содержащую элементы ее вычислительной модели.

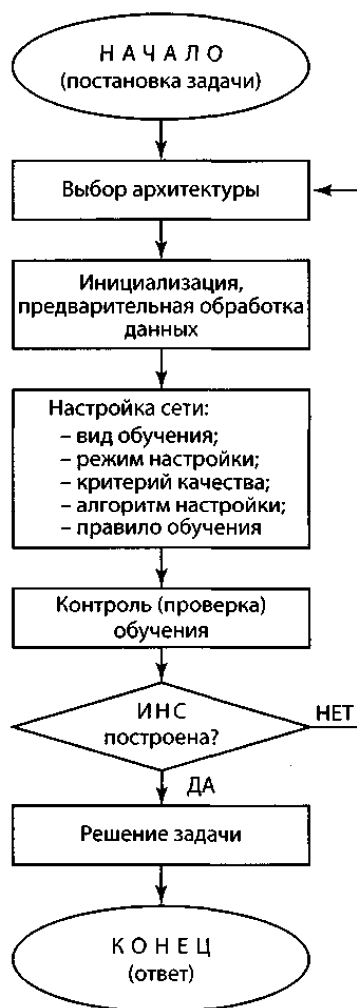


Рис. 4.3. Структурная схема построения ИНС

5. ЧАСТО ПРИМЕНЯЕМЫЕ НА ПРАКТИКЕ ТИПЫ ИНС

5.1. Персептроны

Возможные приложения: задачи классификации линейно отделимых наборов векторов (система векторов называется *линейно отделимой*, если множество точек двумерного (многомерного) пространства, соответствующих векторам системы, можно разбить прямой (гиперплоскостью) на два непересекающихся подмножества).

Архитектура сети. Нейрон персептрона (Ф. Розенблатт, 1957 г.) имеет структурную функцию активации с жестким ограничением (рис. 5.1) или знаковую функцию (см. таблицу 1.1).

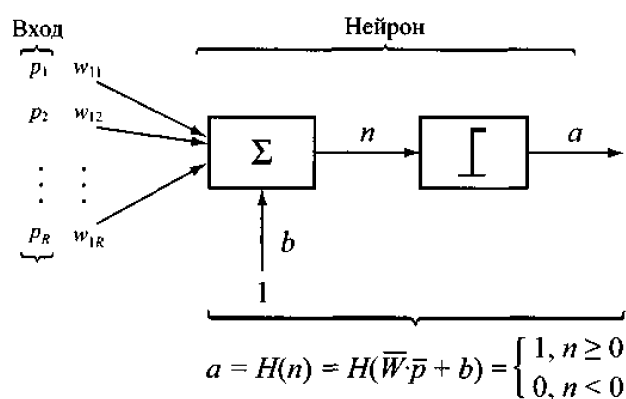


Рис. 5.1. Нейрон персептрона

Под персептроном понимают однослойную или многослойную сеть с прямой передачей сигнала и с указанными выше функциями активации слоев. Чаще всего используется однослойный персептрон, выход каждого нейрона которого может принимать одно из двух значений (0, 1 или $-1, 1$). Многослойные персептроны применяются для приближенной классификации линейно неотделимых систем векторов.

Инициализация персептрона. В качестве функции инициализации можно выбрать любую из перечня, приведенного в п. 4.2.1. Входные векторы обычно подвергаются нормировке. Это очень существенно, когда среди

входных векторов имеются такие, длины которых очень большие или малые (по сравнению с модулями других векторов). Нормировка уменьшает продолжительность настройки сети.

Настройка сети. Обучение персептрона осуществляется с использованием обучающего множества, то есть проводится обучение с учителем, в последовательном режиме. Для изменения параметров сети пользуются правилом *коррекции по ошибке*, построенном на основании разности ошибки \bar{e} между целью \bar{t} и выходом \bar{a} : $\bar{e} = \bar{t} - \bar{a}$. Если рассматривать простейшую однослойную сеть с одним нейроном (см. рис. 5.1), то, учитывая, что $e = t - a$, для вектора $\Delta\bar{w}_1 = (\Delta w_{11}, \Delta w_{12}, \dots, \Delta w_{1R})$ приращений весов Δw_{1j} ($j = 1, \dots, R$) и приращения смещения Δb , получим:

$$\Delta\bar{w}_1 = \begin{cases} 0, & \text{если } e = 0; \\ \bar{p}, & \text{если } e = 1; \\ -\bar{p}, & \text{если } e = -1, \end{cases}$$

то есть $\Delta\bar{w}_1 = (t - a)\bar{p} = e\bar{p}$, а $\Delta b = (t - a)1 = e$.

Значит, приращение Δw_{1j} описывается соотношением:

$$\Delta w_{1j} = ep_j, \quad (5.1)$$

которое и определяет правило коррекции по ошибке.

В качестве критерия качества (функции ошибок) используется средняя абсолютная ошибка (5.6).

Длительность обучения чувствительна к «выбросам» длины отдельных векторов. Чтобы сократить время обучения при наличии малых и больших по длине векторов входа, их, как указано выше, нормируют; тогда правило обучения (5.1) выглядит так:

$$\begin{cases} \Delta\bar{w}_1 = e \frac{\bar{p}}{\|\bar{p}\|}, \\ \Delta b = t - a = e, \end{cases} \quad (5.2)$$

где $\|\bar{p}\| = \sqrt{p_1^2 + p_2^2 + \dots + p_R^2}$ – длина входного вектора.

Один из подходов к решению задачи классификации линейно неотделимых наборов векторов однослойным персептроном состоит в преобразовании заданных векторов \bar{p} в векторы \bar{q} с помощью отображения $\varphi: \bar{p} \rightarrow \bar{q}$ так, что множество $\{\bar{q}\}$ линейно отделимо. Трудность реализации такого преобразования – отыскание отображения φ . Если ее преодолеть не удастся, то применяют многослойные персептроны или сети других типов, например, линейные.

5.2. Линейные сети

Область применения. Линейные ИНС, как и персептроны, решают задачи классификации линейно отделимых систем векторов, а также задачи линейной аппроксимации функций.

Архитектура сети. Нейрон линейной сети отличается от нейрона персептрона пороговой функцией, она выбирается в виде линейной функции $a=f(n)=n$ (см. табл. 1.1). Для решения задачи указанного типа часто бывает достаточно однослойной ИНС. При этом задача классификации с помощью линейной сети всегда разрешима, если суммарное количество весов и смещений равно числу пар векторов входа и цели, то есть мощности обучающего множества:

$$S(R+1) = Q, \quad (5.3)$$

где R – число компонент входного вектора (и вектора цели); S – число нейронов в слое; Q – мощность обучающего множества.

Наряду со статическими линейными ИНС используются динамические сети, то есть сети, содержащие линии задержки. Такие ИНС используются, например, для задач фильтрации и предсказания сигнала, подавления шумов и при проектировании многомерных цифровых фильтров.

Инициализация сети и предварительная обработка исходных данных осуществляется также, как и для персептрона.

Настройка ИНС. Для линейных сетей применяется обучение с учителем. В отличие от персептрона для настройки статических линейных ИНС можно применять как последовательный режим обучения, так и блочный (групповой). Динамические сети настраиваются только в последовательном режиме, поэтому их называют *адаптируемыми* ИНС.

Критерий качества для линейных сетей выбирается более действенным – минимизируется средняя квадратичная ошибка (см. (4.5)). Приращение параметров – весов и смещений – рассчитывается по так называемому *правилу Видроу–Хоффа* в зависимости от параметра настройки η , ошибки e и нормированного вектора входа \overline{pn} :

$$\overline{pn} = \frac{\overline{p}}{\|\overline{p}\|} = \frac{\overline{p}}{\sqrt{1 + p_1^2 + p_2^2 + \dots + p_R^2}}, \quad (5.4)$$

который рассматривается с учетом смещения, то есть полагают $p_0 = 1$. Заметим, что правило коррекции по ошибке параметра настройки не содержит, а это значит, что правило Видроу–Хоффа более гибкое в смысле обеспечения гарантии устойчивости процесса обучения. Минимум функции ошибок отыскивается по алгоритму метода наименьших квадратов.

5.3. Радиальные базисные сети

Возможные применения: задачи классификации, аппроксимации функций, анализа временных рядов, множественного регрессионного анализа и другие вероятностные задачи.

Архитектура. Радиальная базисная сеть состоит из двух слоев: скрытого радиального базисного слоя, имеющего S^1 нейронов, и выходного линейного слоя с S^2 нейронами (рис. 5.2) и соответственно с функциями активации (см. табл. 1.1): $f^1(n) = e^{-n^2}$ (радиальной), $f^1(n) = n$ (линейной). По сравнению с другими сетями с прямой передачей сигнала такие ИНС

содержат большее число нейронов и потому особенно эффективны при большой мощности обучающего множества.

Отличительной чертой скрытого слоя (по сравнению с рассмотренными ранее сетями) является формирование вектора входа радиальной пороговой функции: его координаты определяются как модуль $\|dist\|$ разности между i -м вектором входа \bar{p}_i и i -й вектор-строкой \bar{w}_i матрицы весов W^1 (1.10), $i = 1, \dots, S$, умноженный на смещение b_i^1 нейрона i (предполагается, что число нейронов в слое равно мощности обучающего множества: $S^1 = Q$).




Рис. 5.2. Увеличенная структурная схема радиальной базисной ИНС

При задании вектора входа каждый нейрон радиального базисного слоя выдаст результат в соответствии с тем, насколько близок входной вектор к вектору весов каждого нейрона: если расстояние между векторами \bar{w}_i и \bar{p}_i уменьшается (увеличивается), то выход радиальной пороговой функции увеличивается (уменьшается) и будет приближаться к единице (нулю). Можно сказать, что радиальный базисный слой является индикатором близости входного вектора и вектора весов. В соответствии с этим выходной слой будет давать значения близкие или, наоборот, далекие от весов матрицы W^2 . Смещения \bar{b}^1 (\bar{b}^2) позволяют корректировать степень близости к 1 или 0 (к весам из W^2) соответствующих векторов выхода.

Инициализация радиальных базисных сетей осуществляется специальным образом (отличным от перечисленных в п. 4.2.1), основываясь на векторах обучающего множества.

Настройка сети производится с учителем, критерий качества – среднеквадратичная ошибка, правило обучения базируется на методе наименьших квадратов. Для радиальных базисных сетей процесс обучения может совмещаться с формированием ее архитектуры с помощью так называемой *итерационной процедуры формирования сети*, суть которой состоит в том, что она на каждом шаге добавляет по одному нейрону в скрытый слой. Число нейронов увеличивается до тех пор, пока сумма квадратов ошибок не станет меньше заданного значения или не будет использовано максимальное число нейронов, равное мощности обучающего множества. Существуют различные варианты сетей, отличающиеся способом формирования входного сигнала для второго слоя.

Недостаток радиальных базисных ИНС заключается в том, что работают они относительно медленно, так как выполняют большие объемы вычислений по сравнению с другими типами нейронных сетей.

5.4. Самоорганизующиеся сети Кохонена

Возможные приложения. Задачи, связанные с исследованием топологической структуры данных, объединением их в *кластеры* – группы объектов, сходных в некотором смысле между собой по тем или иным признакам. Такие задачи возникают в различных областях знаний: экономика, финансы, медицина, техника и другие.

Архитектура. ИНС Кохонена – это однослойная сеть с так называемой *конкурирующей функцией активации*, которая обозначается через C и принимает два значения: 1 или 0. Значению выхода a_i ($i = 1, \dots, S$) нейрона с номером i^* , которому соответствует наибольшее значение базовой (сете-

вой) функции n_i , приписывается 1, а всем остальным выходам – значение 0, то есть

$$a_i = C(n_i) = \begin{cases} 1, & \text{если } i = i^*; \\ 0, & \text{если } i \neq i^*, \end{cases} \quad (5.5)$$

где i^* – номер нейрона, который формирует базовую функцию, удовлетворяющую условию

$$n_{i^*} = \max_{i=1, \dots, S} \{n_1, n_2, \dots, n_S\} \text{ или } i^* = \arg(\max n_i).$$

Нейрон, формирующий наибольшее значение базовой функции, называется *нейроном-победителем*. Он как бы «выигрывает состязание» с другими нейронами и, исходя из этой особенности генерирования выходов, такие самообучающиеся ИНС называют *состязательными сетями* (нейронов-победителей может быть несколько). В общем случае состязательные ИНС могут содержать несколько слоев, в отличие от сети Кохонена, которую называют также *слоем Кохонена*.

Слой Кохонена (рис. 5.3) аналогичен скрытому слою радиальной базисной сети в том смысле, что содержит специальный блок $\|negdist\|$ для вычисления отрицательного евклидова расстояния, которое используется при формировании своеобразной (нетрадиционной) базовой функции

$$\bar{u} = net(W, \bar{p}),$$

где $W = (w_{ij})_{S \times R} = (\bar{w}_i)_{S \times 1}$ – весовая матрица слоя; $\bar{w}_i = (w_{i1}, w_{i2}, \dots, w_{iR})$ – вектор весов i -го нейрона (см. (1.10)); $\bar{p} = (p_j)_{R \times 1} = (p_1, p_2, \dots, p_R)^T$ – входной вектор.




Рис. 5.3. Увеличенная структурная схема слоя Кохонена

Значение n_i базовой функции каждого нейрона i вычисляется так: взятое со знаком «минус» евклидово расстояние (как корень квадратный из суммы квадратов разностей координат вектора входа и вектора весов i -го нейрона) складывается со смещением нейрона:

$$n_i = -\sqrt{\sum_{j=1}^R (p_j - w_{ij})^2} + b_i, \quad i=1, \dots, S. \quad (5.6)$$

Из (5.6) следует, что если все смещения нулевые, то максимальное значение n_i не превышает 0; вектор \bar{n} при нулевых смещениях будет нулевым, если строки матрицы весов одинаковы и равны вектору входа; если смещения отличны от 0, то n_i могут принимать как положительные, так и отрицательные значения.

Инициализация слоя. Начальные значения весов часто задаются как среднее значение концов промежутка изменения координат входных векторов или инициализируются случайными значениями с равномерным законом распределения. Применяют также способ задания начальных связей, основанный на обучающем множестве, когда векторы весов нейронов берутся равными входным векторам, и др. Векторы входа, как правило, нормируются.

Обучение слоя может проводиться с учителем (как в последовательном, так и в групповом режиме), когда принадлежность входных векторов определенным классам известна заранее, или без учителя. Предпочтение отдается обучению без учителя. Критерием качества обучения может быть только дифференцируемая функция. Чаще всего минимизируется средне-квадратичная (4.4) или комбинированная ошибка (4.5) одним из градиентных методов.

Для настройки матрицы весов слоя Кохонена пользуются одноименным правилом – *правилом Кохонена*, которое представляет собой рекуррентное соотношение, обеспечивающее коррекцию i -й строки матрицы весов W , то есть вектора \bar{w}_i , добавлением взвешенной разности вектора входа \bar{p} и вектора весов \bar{w}_i предыдущего шага:

$$\bar{w}_i(k+1) = \bar{w}_i(k) + \alpha [\bar{p}(k) - \bar{w}_i(k)], \quad k = 1, \dots, N, \quad (5.7)$$

где k – номер шага настройки; α – параметр скорости настройки, который от шага к шагу может меняться ($0 < \alpha(k) < 1$); $i = i^*$, то есть предполагается, что нейрон i^* победил на k -м шаге при подаче на сеть очередного, k -го, вектора; N – число эпох, которое задается заранее или определяется значением функции ошибок.

Из (5.7) получаем соотношение для приращений весов на k -м шаге:

$$\Delta w_{ij}(k) = \alpha(k) [p_j(k) - w_{ij}(k)], \quad (5.8)$$

где $\alpha(k)$ – параметр скорости настройки – часто вычисляют по формуле

$$\alpha(k) = 1/k, \quad k = 1, 2, \dots \quad (5.9)$$

Как видно, в ходе обучения значения параметра скорости настройки уменьшаются.

Правило Кохонена (5.7) можно записать в виде:

$$\bar{w}_i(k+1) - \bar{p}(k) = (1 - \alpha(k))(\bar{w}_i(k) - \bar{p}(k)). \quad (5.10)$$

Согласно (5.10) вектор весов, наиболее близкий к вектору входа, преобразуется так, что расстояние между ними становится еще меньше. В результате такого обучения победивший нейрон, вероятно, выиграет состязание и в том случае, когда будет представлен новый входной вектор, близкий к предыдущему (см. (5.6)); когда будет подан на вход вектор, существенно отличающийся от предыдущего (по величине расстояния между ним и вектором весов), то его победа менее вероятна, и другой нейрон начнет формировать свой кластер.

В конечно счете, если слой содержит достаточное число нейронов, то каждая группа близких между собой векторов (в смысле малости расстояния между ними) окажется связанной с одним из нейронов слоя, то есть будет произведена кластеризация данных. Правда, это достигается корректировкой значений не только весов, но и смещений.

Настройка смещений нейронов осуществляется так, чтобы избежать ситуации, когда некоторые нейроны (за всю историю из N эпох) ни разу не оказываются победителями; их называют *нейронами-неудачниками*, или «мертвыми» *нейронами*, ведь они не несут никакой полезной информации. Смещения b_i выбираются так, чтобы «неудачник» мог конкурировать с «победителем», этому способствует положительное смещение, которое прибавляется к отрицательному расстоянию «мертвого» нейрона. Одно из правил, развивающее «стремление к победе», заключается в следующем:

1) вначале настройки всем нейронам слоя, количество которых S , выбирается равным известному (или предполагаемому) числу кластеров, присваивается параметр

$$c_i = c_0 = 1 / S, \quad i = 1, \dots, S, \quad (5.11)$$

названный *параметром активности нейрона*, а вектор $\bar{c} = (c_1, c_2, \dots, c_S)$ – *вектором (параметров) активности*;

2) формула для вектора приращений параметров активности выбирается в виде:

$$\Delta \bar{c} = \eta (\bar{a}_{i^*} - \bar{c}), \quad (5.12)$$

где η – параметр скорости настройки активности; \bar{a}_{i^*} – выходной вектор, элемент i^* которого равен 1, а остальные – 0; \bar{c} – вектор активности нейронов;

3) формула для расчета приращений вектора смещений выглядит так:

$$\Delta \bar{b} = e^{1-\ln \bar{c}} - \bar{b}. \quad (5.13)$$

Из (5.13) получаем собственно *правило настройки (обучения) смещений*:

$$\Delta b_i = e^{1-\ln c_i} - b_i = \frac{e}{c_i} - b_i, \quad (5.14)$$

где $e = 2,71828...$

Увеличение смещений для неактивных нейронов позволяет подключить их к формированию своих кластеров, в результате чего входное множество векторов будет поделено (разбито) на большее число меньших по размерам кластеров.

Из сути задачи кластеризации следует, что кластеры как множества векторов-объектов между собой не пересекаются и расстояние между объектами одного кластера меньше, чем их расстояние до объектов другого кластера; между кластерами, нейронами и векторами \bar{w}_i ($i = 1, \dots, S$) их весов устанавливается взаимно однозначное соответствие.

Каждый нейрон можно истолковать как *центр группировки (притяжения)* входных векторов, а его весовой вектор как *обобщенный вектор*, представляющий целый класс входных сигналов.

Напомним, что номер активного нейрона i^* определяет ту группу (класс) объектов, к которой наиболее близок (по величине расстояния) входной вектор. Под *мерой близости* самих нейронов будем понимать рас-

стояние между соответствующими векторами весов нейронов – обобщенными векторами: чем меньше (больше) указанное расстояние, тем ближе (дальше) расположены нейроны (кластеры) по отношению друг к другу.

Немаловажным является вопрос об упорядочении кластеров (нейронов) в смысле их близости друг к другу. Решение этого вопроса осуществляется с помощью модификации слоя Кохонена – *карты Кохонена*, которую называют еще *самоорганизующейся сетью с упорядочением нейронов*.

Архитектура карты Кохонена отличается от архитектуры одноименного слоя тем, что в карте не используются смещения ($b_i = 0$, $i = 1, \dots, S$). Следовательно, компоненты n_i базовой функции \bar{n} – входа функции активации C – имеет вид:

$$n_i = -\sqrt{\sum_{j=1}^R (p_j - w_{ij})^2}, \quad i = 1, \dots, S. \quad (5.15)$$

Инициализация карты и предварительная обработка данных проводится так же, как и для слоя.

Обучение карты принципиально отличается от настройки слоя тем, что после выявления нейрона-победителя (его называют еще *базовым нейроном* карты), обновляются (корректируются) веса не только базового нейрона, но и остальных нейронов сети. Из-за обнуления смещений некоторые нейроны не смогут сформировать свой кластер, но достоинство этого недостатка в том, что впоследствии (при решении задач с помощью сети, а не при ее построении) можно будет из входной информации выделить векторы, которые резко отличаются по своим признакам (свойствам) от векторов, представленных обучающим множеством.

Правило обучения карты – *правило Кохонена* – отличается от правила (5.8) наличием, кроме параметра скорости настройки $\alpha(k)$, так называемого *параметра соседства* нейронов, который регулирует изменение веса нейрона, не являющегося победителем, в зависимости от того, на-

сколько он близок (или далек), судя по расстоянию, к нейрону-победителю:

$$\Delta w_{ij}(k) = \alpha(k) \lambda(i, k) [p_j(k) - w_{ij}(k)], \quad (5.16)$$

где $\lambda(i, k)$ – параметр соседства нейрона i по отношению к базовому нейрону i^* , с обнаружения которого и начинается настройка карты.

В MATLAB $\lambda(i, k)$ определяется так:

$$\lambda(i, k) = \begin{cases} 1, & \text{если } a(i, k) = 1 \text{ и } d(i, i^*) > d; \\ 1/2, & \text{если } a(i, k) = 1 \text{ и } d(i, i^*) \leq d; \\ 0 & \text{в остальных случаях,} \end{cases} \quad (5.17)$$

где $a(i, k)$ – выход i -го нейрона на k -м шаге; $d(i, i^*)$ – расстояние между нейронами i и i^* ; d – числовой параметр, которым определяется множество нейронов, подлежащих обучению.

Параметр d называют *размером окрестности* нейрона-победителя. Начальный размер окрестности назначается равным максимальному расстоянию между нейронами (то есть весовыми векторами нейронов), а потом уменьшается в соответствии со следующим соотношением:

$$d = d(k) = 1,00001 + (\max d - 1) \left(1 - \frac{k}{S_y} \right), \quad (5.18)$$

где $\max d$ – начальный размер окрестности; S_y – фиксированное число циклов, выбранное для упорядочения нейронов (по умолчанию берут $S_y = 1000$).

В соответствии с (5.16), (5.17) весовые векторы нейрона-победителя изменяются пропорционально параметру скорости обучения (как и в слое Кохонена), а веса соседних нейронов (из выбранной окрестности) – пропорционально половинному значению этого параметра.

Процесс обучения карты включает два этапа:

1) *упорядочение весовых коэффициентов* нейронов (а значит, и самих нейронов);

2) *подстройка* карты, когда параметр скорости обучения $\alpha(k)$ уменьшается очень медленно, с целью уточнения значений весов нейронов при сохранении размещения (упорядочения) нейронов, полученного на предыдущем этапе; на втором этапе число шагов должно значительно превышать число шагов на этапе упорядочения и занимать до 80% общего времени обучения.

Для визуального анализа степени соседства (близости) нейронов (кластеров) можно строить карты Кохонена различной размерности: одномерные, двумерные, трехмерные и т.д. Пример одномерной карты Кохонена, соответствующий слою из 5 нейронов, дан на рис. 5.4.




Рис. 5.4. Одномерная карта Кохонена

Нейроны изображаются жирными точками или кружками, сверху указываются номера нейронов. Каждый нейрон, расположенный на концах отрезка $[-2, 2]$, будет иметь единственного «соседа», остальные – двух соседей. Каждый интервал с центром в начале отсчета называют *окрестностью* нейрона-победителя (базового нейрона). Окрестности нумеруются в естественном порядке: по возрастанию длин интервалов. Номера окрестностей называют условно их *радиусами*. На рис. 5.4 $(-1-\epsilon, 1+\epsilon)$ – окрестность радиуса 1 (первая окрестность), $(-2-\epsilon, 2+\epsilon)$ – окрестность радиуса 2 (вторая окрестность), ϵ – положительное число (обычно меньше единицы). Из анализа карты следует, что ближайшими к базовому нейрону являются нейроны (кластеры) 2, 3.

Наиболее удаленные от кластера 1 (по проявлению тех или иных признаков, свойств) кластеры 4, 5.

Если предположить, что множество нейронов сети представляет (заполняет) собой некоторую часть плоскости или трехмерного пространства, то получим соответственно двумерную или трехмерную карту. Окрестности базового нейрона выбираются в виде прямоугольников или шестиугольников (говорят, что выбирается прямоугольная и гексагональная *топологические сетки*); они изображены на рис. 5.5.

Выбор вида топологической сетки никак не влияет на характер упорядочения нейронов. Для рассмотренного выше примера двумерные карты Кохонена изображены на рис. 5.6.

Из рис. 5.6 видно, что и в прямоугольной, и в шестиугольной сетке задействовано по две окрестности базового нейрона. Хотя конфигурации карт разные, но топологическое свойство соседства нейронов осталось неизменным.




Рис. 5.5. Виды топологических сеток: а) прямоугольная, б) гексагональная




Рис. 5.6. Карты Кохонена: а) прямоугольная, б) гексагональная

Проследим в описательном плане на примере, как делается карта Кохонена.

Пусть для обучения сети, которая рассматривается как двумерный массив из 6-ти нейронов, заданы 12 двумерных векторов с диапазонами изменения элементов от 0 до 2.

Построим на плоскости (рис. 5.7, а) вершины (концы) векторов входа и начальных весовых векторов, координаты которых инициализируем, выбрав их равными среднему арифметическому наименьшего и наибольшего значений из диапазонов (отрезков) значений их координат, то есть положим $w_{i1} = 1$, $w_{i2} = 1$, $i = 1, \dots, 6$. После обучения сети – этапов упорядочивания и подстройки – получим собственно карту Кохонена (рис. 5.7, б).




Рис. 5.7. Начальное расположение весов и векторов входа (а) и топографическая карта сети (б)

На рис. 5.7, а звездочками отмечены концы векторов входа, а полностью изображен начальный весовой вектор (1, 1), общий для всех нейронов. В процессе обучения весовые векторы изменялись и в итоге получили значения, которыми и определяется положение каждого нейрона, являющегося центром группировки данных. Нетрудно заметить, что задействована гексагональная сетка (в системе MATLAB она используется по умолчанию). При больших количествах нейронов карта Кохонена ассоциируется с гибкой рыбацкой сетью со многими крючками в узлах, ко-

торая забрасывается во множество рыбок-векторов. Пойманные на крючки одного узла рыбки составляют своеобразный кластер.

Отметим также, что MATLAB предлагает четыре вида расстояний:

1) евклидово

$$d(\bar{x}, \bar{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2};$$

2) расстояние максимального координатного смещения

$$d(\bar{x}, \bar{y}) = \max_i |x_i - y_i|;$$

3) расстояние суммарного координатного смещения

$$d(\bar{x}, \bar{y}) = \sum_{i=1}^n |x_i - y_i|;$$

4) расстояние связи между нейронами слоя, которое описывается числами $1, 2, 3, \dots, S$, чтобы задать путь движения от базового нейрона до других нейронов: если евклидово расстояние между нейронами меньше или равно 1, то расстояние связи принимается равным 1; если между нейронами с номерами i, j имеется единственный промежуточный нейрон с номером k , то расстояние связи равно 2, и так далее до S . Например (см. рис. 3.7, б), расстояние связи между базовым нейроном 1 и нейронами 2, 3 равно 1; между базовым нейроном и нейронами 4, 5 равно 2; между базовым нейроном и нейроном 6 равно 3.

Дальнейшим развитием самоорганизующихся сетей Кохонена являются сети для кластеризации и классификации векторов (*LVQ-сети*). LVQ-сеть мы получим, если к карте Кохонена добавим линейный слой, или, по-другому, если в радиальной базисной сети (см. рис. 5.2) конкурирующий слой заменим картой Кохонена. Конкурирующий слой выполняет кластеризацию векторов, а линейный (выходной) слой соотносит кластеры с целевыми классами, заданными исследователем.

5.5. Рекуррентные сети

5.5.1. Сеть Элмана

Возможные приложения: задачи создания систем управления движущимися объектами, систем технического зрения и другие задачи, для решения которых нужно учесть предысторию изучаемых процессов для выработки правильной стратегии, например, задачи экономического прогнозирования.

Архитектура сети. Сеть Элмана – это, как правило, ИНС-2, в которой скрытый слой охвачен динамической обратной связью. В качестве функций активации часто используется: в скрытом слое – функция гиперболического тангенса, в линейном слое – линейная функция (рис. 3.8).

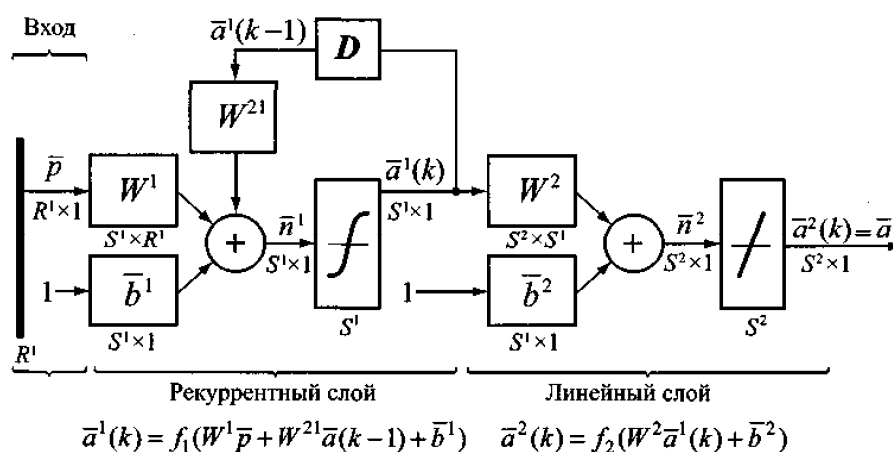


Рис. 5.8. Увеличенная структурная схема сети Элмана

Кроме уже знакомого элемента задержки D , отличительным по сравнению со статическими сетями элементом ИНС Элмана является матрица весов W^{21} обратной связи, входной вектор для которой на k -м шаге формируется выходом скрытого слоя на $(k-1)$ -м шаге.

Инициализация весов и смещений осуществляется случайным образом или применением специального алгоритма Нгуен – Видроу, если слои имеют смещения.

Настройка сети производится без учителя при последовательном представлении данных. В качестве функции ошибок берутся среднеквадратичная или комбинированная ошибки. Алгоритм настройки - алгоритм градиентного спуска с возмущением *GDM* (см. п. 4.3.2). Дифференциалы весов $d\bar{W}$ рассчитываются в зависимости от градиента критерия качества \bar{g} по вектору весов, параметрам скорости настройки η и возмущения μ в соответствии с методом градиентного спуска с возмущением:

$$d\bar{W} = \mu d\bar{W}_0 + (1 - \mu)\eta\bar{g}, \quad (5.19)$$

где $d\bar{W}_0$ – вектор приращений предыдущего шага.

Коррекция весов и смещений производится с использованием метода обратного распространения ошибки.

Сети Элмана не обеспечивают высокой точности решения, поскольку присутствие обратной связи в рекуррентном слое не позволяет вычислить точно градиент функции ошибок.

В MATLAB есть специальная функция формирования (создания) сетей Элмана.

5.5.2. Сеть Хопфилда

Возможные приложения. Проектирование устройств, обладающих свойством переходить с течением времени из произвольного начального состояния в то или иное состояние устойчивого равновесия. В частности, разработка средств ассоциативной памяти для интеллектуализации современных ЭВМ. В общем плане – это решение задач распознавания образов.

Архитектура сети. Сеть Хопфилда – это ИНС без входов, содержащая один рекуррентный слой (рис. 5.9) с шаговой (симметричной линейной с ограничениями) функцией активации (см. табл. 1.1).

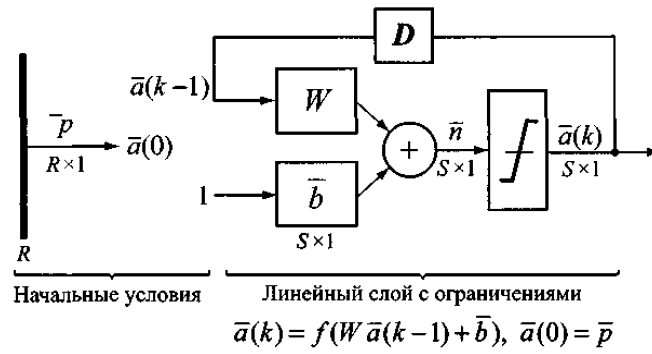


Рис. 5.9. Укрупненная структурная схема сети Хопфилда

Особенность сети Хопфилда состоит в том, что она не имеет входов, а задаются лишь те или иные начальные условия – выход сети (состояние системы) на нулевом ($k=0$) шаге.

Инициализация сети производится целевыми векторами (они описывают состояния равновесия системы). После того как начальные условия заданы, сеть генерирует выход, который по обратной связи подается на вход. Этот процесс повторяется много раз, пока выход не установится в одно из положений равновесия.

Обучение сети как раз и заключается в том, чтобы приводить случайные входные векторы к точкам равновесия, которые соответствуют определенным, заданным пользователем, целям. Своеобразие настройки сети Хопфилда определяется тем, что уравнение функционирования рекуррентного слоя

$$\bar{a}(k) = f(W \cdot \bar{a}(k-1) + \bar{b}), \quad \bar{a}(0) = \bar{p} \quad (5.20)$$

по своей структуре является таким же, как описание динамических систем (с помощью дифференциальных уравнений) после их дискретизации. Поэтому создание сети основано на построении и решении системы линейных дифференциальных уравнений первого порядка, соответствующей уравнению (5.20). Для этой цели разработаны специальные методы.

Когда сеть спроектирована, она может быть проверена с одним или большим числом векторов входа. Как правило, векторы входа, близкие к

векторам равновесия, находят свои цели. Сеть Хопфилда несовершенна в том смысле, что синтезируемая ИНС в дополнение к желаемым может генерировать лишние точки равновесия, их называют *паразитными*. Существуют алгоритмы, минимизирующие число устойчивых паразитных точек равновесия. В системе MATLAB есть специальная функция формирования сетей Хопфилда.

Кроме рассмотренных в п. 3 сетей, существуют и другие виды ИНС, например, *сеть Хэмминга* – ИНС-2 с прямыми связями, которая решает задачу распознавания для бинарных входных векторов; *неокогнитрон* – многослойная самоорганизующаяся ИНС, которая решает задачу кластеризации в случае нескольких нейронов победителей.

6 ПРИКЛАДНЫЕ ВОЗМОЖНОСТИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Технология обработки информации посредством искусственных нейронных сетей используется главным образом в тех случаях, когда требуется решать задачи аппроксимации, классификации и распознавания образов, прогнозирования, идентификации и оценивания, ассоциативного управления [1]. Широкое признание, полученное нейронными сетями, обусловлено несколькими причинами.

Богатые возможности. С помощью ИНС стало возможным строить математические модели, отображающие любые, сколько угодно сложные связи между переменными-предикторами (входами) и прогнозируемыми переменными (выходами). Задачи подобного рода встречаются повсеместно, т.к. практически в каждой проблеме, решаемой прикладными науками, требуется строить модель явления, процесса, объекта, т.е. выявлять и математически описывать зависимость одного комплекса параметров от другого, строить математические функции, которые можно было бы использовать для более глубокого анализа объекта, например, находить оптимальное сочетание управляющих параметров, обеспечивающих максимум целевой функции, выполнять прогнозирование, предсказывать, как будут развиваться события в зависимости от того или иного воздействия [23].

На протяжении многих лет классический путь создания математических моделей тех или иных процессов включал в себя этапы изучения, анализа и использования фундаментальных законов природы. Аппарат нейронных сетей ознаменовал собой качественно иной подход к методу математического моделирования – появилась возможность, не задумываясь над законами физики, химии, биологии, экономики, статистики и т. д., а исходя лишь из одного только эмпирического опыта (обучающей выбор-

ки) строить математические модели, которые сами извлекают эти законы и позволяют эффективно их использовать для решения широкого круга прикладных задач [23]. Таким образом, искусственная нейронная сеть, являясь универсальным средством выявления ранее неисследованных и доселе неизвестных зависимостей и закономерностей, представляет собой исключительно мощный инструмент обработки информации в арсенале современной науки.

Простота в использовании. Нейронные сети не программируются в привычном смысле этого слова, они обучаются [12]. Пользователь нейронной сети подбирает репрезентативную выборку и запускает алгоритм обучения, в процессе которого выполняется подбор коэффициентов связей между нейронами сети для максимально точного отображения входного вектора параметров на выходной. При этом от пользователя требуется лишь определённый набор знаний о том, как следует отбирать и подготавливать данные для обучения и тестирования сети, каким образом осуществлять выбор оптимальной архитектуры ИНС и интерпретировать результаты выполненного моделирования.

Помимо прочего нейронные сети привлекательны даже с интуитивной точки зрения, т.к. они основаны на простейшей биологической модели нервных систем [3]. В будущем развитие таких нейробиологических моделей может привести к созданию действительно «мыслящих» компьютеров.

6.1 Нейросетевой детектор лжи

Применяемые на сегодняшний день в следственной практике МВД России полиграфы имеют систему датчиков, измеряющих до десяти различных параметров: начиная от пульса, артериального давления, температуры тела, частоты дыхания проверяемого и заканчивая электросопротивлением отдельных участков кожи [23].

Тем не менее даваемое по результатам проверки заключение полиграфолога не является в полной мере корректным, т.к. разные люди по-разному реагируют на стрессовые ситуации, в то время как методика анализа полиграм одинакова.

Принцип использования нейронной сети для выявления признаков лжи не отличается от описанной ранее задачи диагностирования в медицине. В качестве входных параметров сети x_1, x_2, \dots, x_{10} следует использовать тот же набор критериев (пульс, давление, температура и т.д.), что и для обычного полиграфирования. При этом персептрон может обладать единственным выходом y – в случае правды $y=1$, если же человек лжёт – $y=0$.

Обучающая выборка сети сформируется в ходе предварительных бесед с подсудимым, для чего следователь станет задавать вопросы, ответы на которые ему заранее известны – таким образом, собранная информация позволит ИНС научиться учитывать индивидуальные психофизиологические особенности человека, которому предстоит давать показания.

Другим способом реализации нейросетевого детектора лжи является использование персептрона, обученного по ответам нескольких людей различного психотипа – такой полиграф менее точен, однако более удобен в случаях, когда затраты времени на предварительные беседы с проверяемым необоснованны.

6.2 Диагностика в медицине

Исследования, проведённые в Боткинской больнице г. Санкт-Петербурга, показали широкие возможности использования нейросетевой технологии диагностики заболеваний [11].

Прежде чем моделировать деятельность врача, необходимо определиться с размерностью входного X и выходного Y векторов сети и условиями с их содержимым. В векторе X необходимо предусмотреть параметры, которые выясняет врач при осмотре больного:

- x_1 – пол;
- x_2 – возраст;
- x_3 – вес больного;
- x_4 – наличие/отсутствие вредных привычек;
- x_5 – температура тела;
- x_6 – артериальное давление;
- x_7, x_8, \dots, x_n – иные данные, учитывающие особенности организма или прямо указывающие на наличие болезней определённого класса.

В выходном векторе Y кодируются все возможные диагнозы болезней, которые могут быть обнаружены врачом; естественно, что для врача узкой специализации размерность вектора Y будет гораздо меньшей – например, в случае использования ИНС для диагностики кардиологических заболеваний в качестве параметра y_1 можно закодировать инфаркт, y_2 – порок сердца, y_3 – ишемию и т.д.

Следующим этапом является подготовка врачом-экспертом и программистом обучающей выборки данных – для различных сочетаний величин параметров вектора X определяются соответствующие значения параметров вектора Y , отображающие в одном варианте осуществления сети точный диагноз, либо в другом варианте – степень уверенности эксперта в своём диагнозе по пяти-, десяти- или стобалльной шкале.

После подбора архитектуры персептрона (числа скрытых слоёв, кол-ва нейронов, вида функции активации) с учётом накопленных примеров производится обучение сети. Наиболее распространённым методом обучения является алгоритм обратного распространения ошибки.

В конце концов при появлении не обращавшегося ранее в больницу пациента (подаче на вход сети данных, не участвовавших при обучении) персептрон, *обобщив* переданный ему опыт, без помощи врача-эксперта должен вычислить вектор Y , соответствующий правильному диагнозу.

Функционирование подобной нейροкомпьютерной системы диагностики заболеваний, созданной с применением программы-имитатора нейронной сети Neural Planner, подробно описывается в [11].

За рубежом возможности нейронной сети для постановки диагнозов активно используются в повседневной практике, чему, например, посвящён ряд статей в журнале Nature Biomedical Engineering. В частности, несомненным успехом является применение китайскими специалистами нейрокомпьютерной экспертной системы (рис. 6.1) для выявления врождённой катаракты [10].

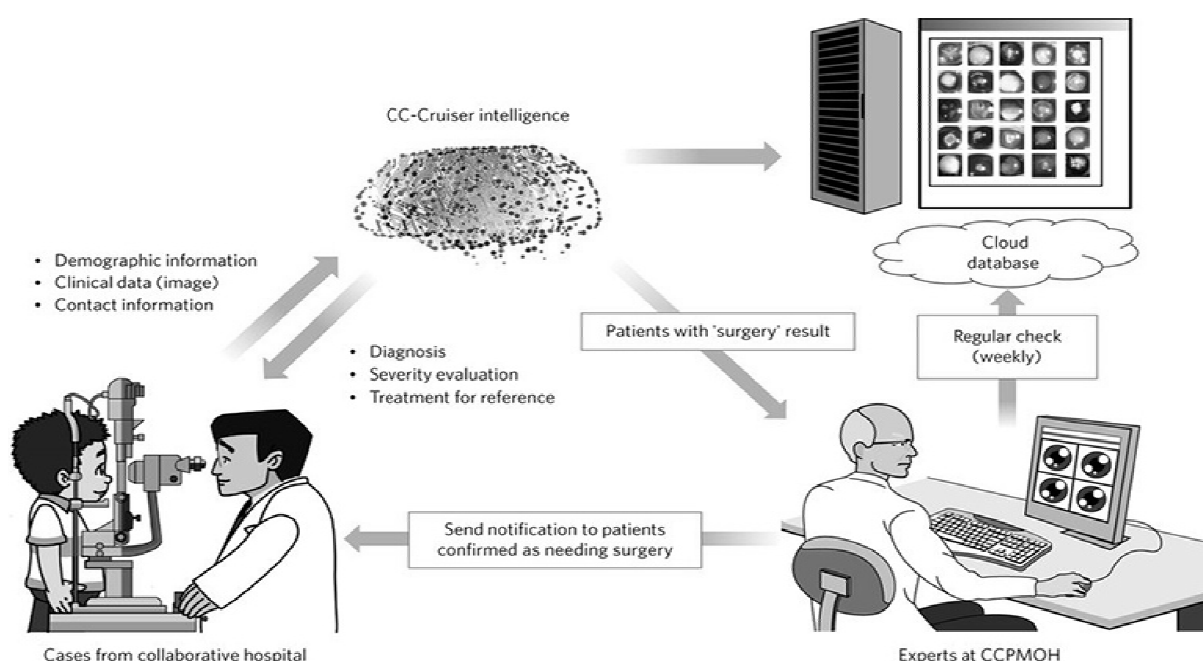


Рис. 6.1. Методика применения искусственной нейронной сети для раннего выявления врождённой катаракты

6.3 Обнаружение неисправностей сложных технических систем

Рассмотренная выше методика использования ИНС для постановки диагнозов в медицине с большим успехом может применяться и в отношении сложных технических систем, а именно – выявлению их неисправностей, в том числе в режиме реального время, после процедуры обучения. Классическим примером демонстрации этой идеи является описание ней-

росетевого подхода к диагностике турбореактивных двигателей, о чём упоминается в [23].

Для измерения параметров функционирования авиадвигателей специалисты устанавливаются на борту воздушного судна большое количество соответствующих датчиков. При этом число фиксируемых таким образом параметров может достигать более сотни, будь то температура и давление воздуха при заборе в двигатель, температура и давления газа за турбиной, нагрев лопаток турбины, нагрев и уровень масла в маслблоке и т.д. В целом же количество подобных показателей соизмеримо с числом анализируемых врачом параметров пациента при постановке его диагноза, в связи с чем упомянутая параллель между применением нейронных сетей в медицине и технике очевидна.

По истечении заданного времени, как правило, после совершения около двухсот полётов двигатель демонтируется с самолёта и подвергается разборке на специальном стенде с целью окончательного выявления и устранения всех дефектов. Всего подобных дефектов около 30 видов, среди которых наиболее распространёнными являются трещины на сопловом агрегате, забоины, повреждения дефлектора, наличие стружек в масле и т.п.

Несомненно, что наибольший интерес вызывает проблема выявления дефектов двигателя до его профилактической разборки. Следуя традиционным путём решения данной задачи, необходимо обнаружить определённые физические закономерности, сопровождающие тот или иной дефект, т.к. следствием каждой неисправности является отклонение соответствующего полётного параметра. В силу этого, анализируя изменение параметров, фиксируемых во время работы двигателя, становится возможным выявление дефектов, вызывающих характерные девиации. Естественно, что, учитывая колоссальный объём обрабатываемой информации, а также сложность взаимосвязей между дефектами и измеренными параметрами, задача сопоставления результатов полётного мониторинга с выявляемыми

неисправностями двигателей для людей-экспертов является крайне трудной и объективно нерешаемой либо же реализуемой с известными допущениями. В связи с этим обратимся к методу нейросетевого моделирования.

Во-первых, необходимо отметить, что входной вектор персептрона X должен содержать все контролируемые в полёте самолёта параметры, на значения которых оказывает влияние появление обнаруживаемых дефектов. Предполагаемые дефекты авиационного двигателя кодируются посредством нулей и единиц в выходном векторе Y . Результаты стендовых разборок двигателей отражаются в значениях, заносимых в векторы желаемых выходов D_q .

Во-вторых, следует предположить, что в момент первых вылетов нового или отремонтированного самолёта его двигатель ещё не содержит дефектов и потому полностью исправен, в то время как последние вылеты самолёта характеризуются наличием всех тех дефектов, которые и выявлялись при разборке двигателя. Таким образом, для обучения нейронной сети учебная выборка формируется на основе наиболее релевантных данных, а именно – параметров первого и последнего полётов самолёта.

Как показывает практика, при наличии достаточного количества обучающих примеров правильно сконфигурированный многослойный персептрон научится качественным образом диагностировать неисправности реактивных двигателей, включая те дефекты, которые в обучающей выборке не содержались. Очевидно, что наличие такого персептрона в бортовом компьютере воздушного судна позволит контролировать появление дефектов в двигателе в режиме реального времени, т.е. при обнаружении соответствия между конфигурацией вектора входных параметров и результатами измерений, выполняемых автоматически во время полёта.

В завершение следует необходимо упомянуть о том, что искусственная нейронная сеть способна выявлять и те взаимосвязи, о которых спе-

циалисты не знают или же не могут объяснить физическую природу их возникновения – эта особенность ИНС является большим преимуществом данного аппарата перед традиционными, основанными на явных знаниях методиками. Например, как отмечается в [2], дефект «стружка в масле» не оказывает сколько-нибудь заметного влияния ни на один из измеряемых высокочувствительными датчиками параметров, вследствие чего каким-либо традиционным методом выявить подобный дефект крайне затруднительно. Тем не менее нейронной сети это под силу, что открывает большие перспективы для построения интеллектуальных диагностических систем. Природа же подобной «интуиции» нейронной сети может заключаться в том, что появление металлической стружки в моторном масле если и не оказывает значительного влияния на какой-либо отдельный фиксируемый параметр, всё же влияет на общую структуру входного вектора, благодаря чему и возможен отклик нейронной сети.

6.4 Мониторинг аварийных режимов воздушных линий электропередачи

Повышение надёжности воздушных линий электропередачи (ВЛЭП) является одним из приоритетных направлений развития электроэнергетики. Это объясняется частой повреждаемостью воздушных линий, что делает их самым уязвимым элементом электрической сети. Использование ИНС позволит создать устройство, выполняющее непрерывный анализ данных о текущем состоянии воздушной линии с целью обучения максимально корректной на данный промежуток времени реакции на входные образы.

Синергетическое взаимодействие устройств, составляющих информационно-измерительную систему, отражает её структурная схема, изображённая на рис. 6.2.




Рис. 6.2. Структурная схема информационно-измерительной системы

Как показано на данном рисунке, предлагаемая информационно-измерительная система (ИИС) включает в себя совокупность элементов, необходимых для сбора информации о текущем состоянии линии (n гололёдных постов с возможностью измерения температуры t и провисания f провода, дополненные датчиками проводимости грунта γ), а также нейроблок обработки информации, подключаемый к измерительным цепям трансформаторов ТА и TV совместно с устройствами релейной защиты.

Главные функциональные части, составляющие структуру адаптивного устройства диагностики коротких замыканий, приведены на рис. 6.3. На выходе измерительной преобразовательной части 1 и коммуникационного модуля 2 по совокупности соответственно входных токов $i(t)$, напряжений $u(t)$, а также данных с измерительных постов, располагаемых на линии, формируется массив информации, характеризующий текущий режим работы электрической сети. Блок интеллектуального анализа данных 3 включает в себя модули подготовки исходных данных 4 и эмуляции нейронной сети 5, при этом 4 выполняет формирование обучающей выборки, содержащей актуальную информацию о состоянии линии, и переобучение нейронной сети. Блок ввода-вывода 6 осуществляет приём сигналов 3 и

выдачу результатов анализа входных данных оператору сети, а источник оперативного тока 7 обеспечивает питание всех компонентов устройства.




Рис. 6.3. Нейроблок обработки информации

Эмуляция среды нейрокомпьютера может осуществляться посредством ЭВМ с загруженной на исполнение управляющей программой. Структурно модуль эмуляции нейронной сети включает в себя два элемента, а именно нейросеть-классификатор и нейросеть-локатор.

Нейросеть-классификатор. Назначением нейронного классификатора аварий является выдача правильного заключения о принадлежности входного образа (вектора данных) к тому или иному классу (виду аварии). При этом вектор входных данных должен содержать 7 элементов: $U_A/U_{\text{ном}}$, $U_B/U_{\text{ном}}$, $U_C/U_{\text{ном}}$, $I_A/I_{\text{ном}}$, $I_B/I_{\text{ном}}$, $I_C/I_{\text{ном}}$, I_0 , где U_A , U_B , U_C , I_A , I_B , I_C – действующие значения напряжений и токов соответствующих фаз; $U_{\text{ном}}$, $I_{\text{ном}}$ – значения напряжения и тока линии до аварии; I_0 – логическая переменная, отражающая наличие ($I_0=1$) или отсутствие ($I_0=0$) тока нулевой последовательности. В силу того, что линии электропередачи напряжением 110 кВ и выше выполняются с эффективно заземленной нейтралью, присутствие в токах составляющих нулевой последовательности является индикатором замкнутого контура через землю, а их отсутствие – исключительно металлического характера короткого замыкания. Кодирование выходной информации о типе повреждения требует четырёх узлов (0000 – нет аварии, 0001 – однофазное замыкание А -> G, 0010 – В -> G, 0011 – С -> G, 0100 – А -> В, ..., 1011 – А -> В -> С -> G).

В ходе исследования данные для «учебных» и «тренировочных» выборок формировались посредством имитации КЗ (на расстоянии 10, 70, 130, 190, 250 км от источника питания) в Simulink-модели электрической сети напряжением 110 кВ (рис. 6.4) и записи соответствующих осциллограмм (рис. 6.5).

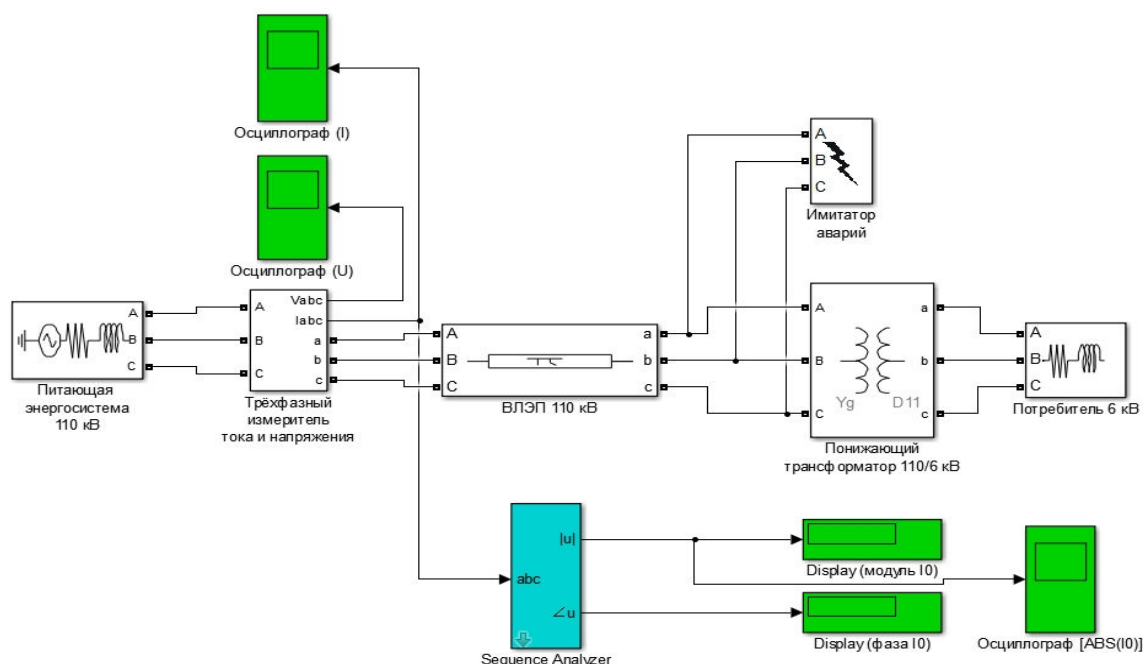


Рис. 6.4. Модель распределительной электрической сети 110 кВ

«Учебник» для нейросети-классификатора может иметь приведённый в табл. 2 вид.

Табл. 2. Учебная выборка данных для классификации типа аварий

Входной вектор							Выходной вектор				Тип КЗ
$\frac{U_A}{U_{\text{ном}}}$	$\frac{U_B}{U_{\text{ном}}}$	$\frac{U_C}{U_{\text{ном}}}$	$\frac{I_A}{I_{\text{ном}}}$	$\frac{I_B}{I_{\text{ном}}}$	$\frac{I_C}{I_{\text{ном}}}$	I_0	Y_1	Y_2	Y_3	Y_4	
0,990	0,990	0,990	1,011	1,011	1,011	0	0	0	0	0	-
0,275	0,965	0,954	10,709	1,388	1,607	1	0	0	0	1	A-G
0,431	0,963	0,956	8,632	1,422	1,615	1	0	0	0	1	
0,532	0,963	0,959	7,279	1,439	1,606	1	0	0	0	1	
0,603	0,963	0,962	6,325	1,418	1,562	1	0	0	0	1	
0,656	0,964	0,965	5,610	1,401	1,526	1	0	0	0	1	
0,954	0,75	0,965	1,607	10,709	1,388	1	0	0	1	0	B-G
0,956	0,431	0,963	1,615	8,632	1,422	1	0	0	1	0	
0,959	0,532	0,963	1,606	7,279	1,439	1	0	0	1	0	
0,962	0,603	0,963	1,562	6,325	1,418	1	0	0	1	0	
0,965	0,656	0,964	1,526	5,610	1,401	1	0	0	1	0	
...




Рис. 6.5. Осциллограммы однофазного КЗ: тока I_0 (а), фазных токов (б)

Количество нейронов в n скрытых слоях сети (рис. 6.6) определяется в соответствии с правилом «пирамиды» следующим образом [82]:

$$N_i = N_{\text{вых}} \cdot s^{i-1}, i = \overline{1, n},$$

где

$$s = \sqrt[n]{\frac{N_{\text{вх}}}{N_{\text{вых}}}}.$$

С учётом данного эмпирического правила многослойный нейронный классификатор (рис. 14) может иметь структуру 7-6-5-4 (2 скрытых слоя с 6-ю и 5-ю нейронами соответственно) или 7-5-4, при этом нейросеть с большим количеством слоёв обладает лучшей скоростью обучения (262 эпохи против 360).




Рис. 6.6. Структура многослойной нейронной сети: трёхслойный персептрон (а), четырёхслойный персептрон (б)

Нейросеть-локатор. Функционирование нейронного локатора аварий требует обновления обучающей выборки (отвечающей текущему, фиксируемому датчиками состоянию линии) и переобучения. Отметим, что количество примеров, обучающих сеть распознаванию аварий на различных участках линии, должно иметь неравномерное распределение по её длине: так, число примеров, характеризующих аварии на участке линии с наиболее интенсивным гололёдообразованием должно превышать количество примеров для участка с наименьшей вероятностью повреждения.




Рис. 6.7. Нейронный классификатор повреждений

Вероятность повреждения воздушной линии представляет собой вероятность того, что скорость ветра превысит некоторое критическое значение v_{max} , при котором механическое напряжение σ_{max} , соответствующее удельной нагрузке γ_{max} на провод при текущей толщине гололёдной муфты b

$$\gamma_{max} = \frac{v_{max}^2 \cdot C_x (d + 2b)}{1,6F} \sin \bar{\varphi},$$

где C_x – коэффициент лобового сопротивления провода, покрытого гололёдом, d – диаметр провода, $\bar{\varphi}$ – среднее за текущий период времени значение угла между направлением ветра и осью ВЛЭП, превысит предел прочности на растяжение.

Как известно из [18], в теории метеорологии вероятность того, что скорость ветра превысит некоторое значение v_{max} , определяется в соответствии с двухпараметрическим распределением Вейбулла:

$$P(v_{max}) = e^{-\left(\frac{v_{max}}{\beta}\right)^{\alpha}}, \quad (6.1)$$

где α и β – параметры функции распределения, при этом α вычисляется посредством эмпирической формулы Л.Б. Гарцмана [18]

$$\alpha = C_v^{-1,069}, \quad (6.2)$$

где C_v – коэффициент вариации скоростей ветра, а для нахождения β применяется уравнение [18]

$$\beta = \frac{\bar{v}}{\Gamma\left(1 + \frac{1}{\alpha}\right)}, \quad (6.3)$$

где \bar{v} – средняя скорость ветра за рассматриваемый период времени, $\Gamma(1 + 1/\alpha)$ – значение гамма-функции.

Таким образом, выражения (6.1)-(6.3) позволяют рассчитать вероятность обрыва провода P_i на каждом i -м участке линии, заключённом между измерительными постами (см. рис. 6.2), с учётом текущих параметров

климатического воздействия, а именно ветрового давления и толщины гололёдной муфты.

Подбор наиболее рациональной корреляционной зависимости между вероятностью аварии P_i и количеством примеров k_i , «обучающих» нейросеть нахождению места повреждения на i -м участке линии ($i = \overline{1, n}$), может осуществляться эмпирически путём выбора полуширины c колокола гауссианы $g(P)$ следующим образом:

$$k_i = \frac{K \cdot g(P_i)}{\sum_{j=1}^n g(P_j)}, \quad (6.4)$$

при этом K – общее количество «обучающих» примеров, а

$$g(P_i) = a \cdot e^{-\frac{(P_i - P_{max})^2}{2c^2}}, \quad (6.5)$$

или, объединяя (6.4) и (6.5),

$$k_i = \frac{K \cdot e^{-\frac{(P_i - P_{max})^2}{2c^2}}}{\sum_{j=1}^n e^{-\frac{(P_j - P_{max})^2}{2c^2}}}, \quad (6.6)$$

где P_{max} – максимально зафиксированная вероятность повреждения линии.

Удобство применения функции Гаусса для оценки распределения обучающих примеров по участкам воздушной линии с учётом вероятности их повреждаемости проиллюстрируем наглядным примером.

Пусть для «обучения» нейросети определению мест повреждений на ВЛЭП формируется «учебник» из 40 обучающих примеров, при этом согласно текущим данным, поступающим от измерительных постов, вероятность аварий, исходя из зонирования линии на 6 участков, составляет соответственно 15, 26, 40, 75, 34 и 28 % соответственно. Тогда, как видно из графиков, приведённых на рис. 15, при $c = 38$ количество «обучающих» примеров, приходящихся на каждый участок ВЛЭП, практически прямо

пропорционально вероятности аварии, при $c = 26$ данная зависимость близка к квадратичной, а при $c = 1000$ ($c \rightarrow \infty$) количество примеров инвариантно вероятности повреждения.

Следовательно, применение уравнения (6.6) путём вариации переменной c позволяет задавать любой характер корреляции между вероятностью аварии и количеством примеров в «учебнике» нейросети, включая полную инвариантность данных величин.

Табл. 3. Параметры «обучаемости» многослойной нейросети различной структуры

Кол-во скрытых слоёв	Структура	Кол-во эпох «обучения»
0	6-1	∞
1	6-3-1	1865
2	6-3-2-1	1593
3	6-4-3-2-1	138
4	6-5-4-3-2-1	428




Рис. 15. Зависимость количества «обучающих» примеров от вероятности повреждения соответствующего участка сети

Как видно из табл. 3, оптимальная структура нейросети-локатора (рис. 6.8) отображается формулой 6-4-3-2-1 (6 входных узлов $U_A/U_{\text{ном}}$, $U_B/U_{\text{ном}}$, $U_C/U_{\text{ном}}$, $I_A/I_{\text{ном}}$, $I_B/I_{\text{ном}}$, $I_C/I_{\text{ном}}$, 3 скрытых слоя и нейрон выходного слоя, указывающий дистанцию L до места аварии).




Рис. 6.8. Нейронный локатор повреждений

Изменяя параметр c от 20 до 250 и варьируя тем самым количество обучающих примеров, приходящихся на каждый из 6 участков линии, была получена изображённая на рис. 17 зависимость погрешности «обучения» нейролокатора ΔL_{min} , ΔL_{max} при нахождении расстояния до места повреждения соответственно в зонах с наименьшим и наибольшим риском аварии.




Рис. 6.9. Влияние параметра c гауссианы на точность «обучения» нейролокатора аварий

Из приведённых на рис. 6.9 графиков следует, что с учётом указанных выше вероятностей повреждаемости (15, 26, 40, 75, 34 и 28 %) наибо-

лее оптимальным является значение $c = 26$, что соответствует 2, 4, 9, 13, 7 и 5 «обучающим» примерам при $\Delta L_{min} = 2,70$ км и $\Delta L_{max} = 0,78$ км.

Алгоритм функционирования нейроблока адаптивной информационно-измерительной системы, состоящий из нейронного классификатора (НКА) и локатора (НЛА) аварий, задаётся блок-схемой, изображённой на рис. 18. Из анализа данного алгоритма следует, что «адаптивность» предлагаемой ИИС достигается посредством обновления с заданной дискретностью по времени «учебника» нейросети на основе данных о климатическом воздействии, поступающих с измерительных постов. Таким образом достигается «переобучение» уже «натренированного» ранее НЛА с учётом более актуальной на текущий момент математической модели ВЛЭП. Предварительное выявление вида аварии посредством НКА позволяет задавать весовые коэффициенты НЛА, полученные при его «обучении» определению места повреждения конкретного типа.

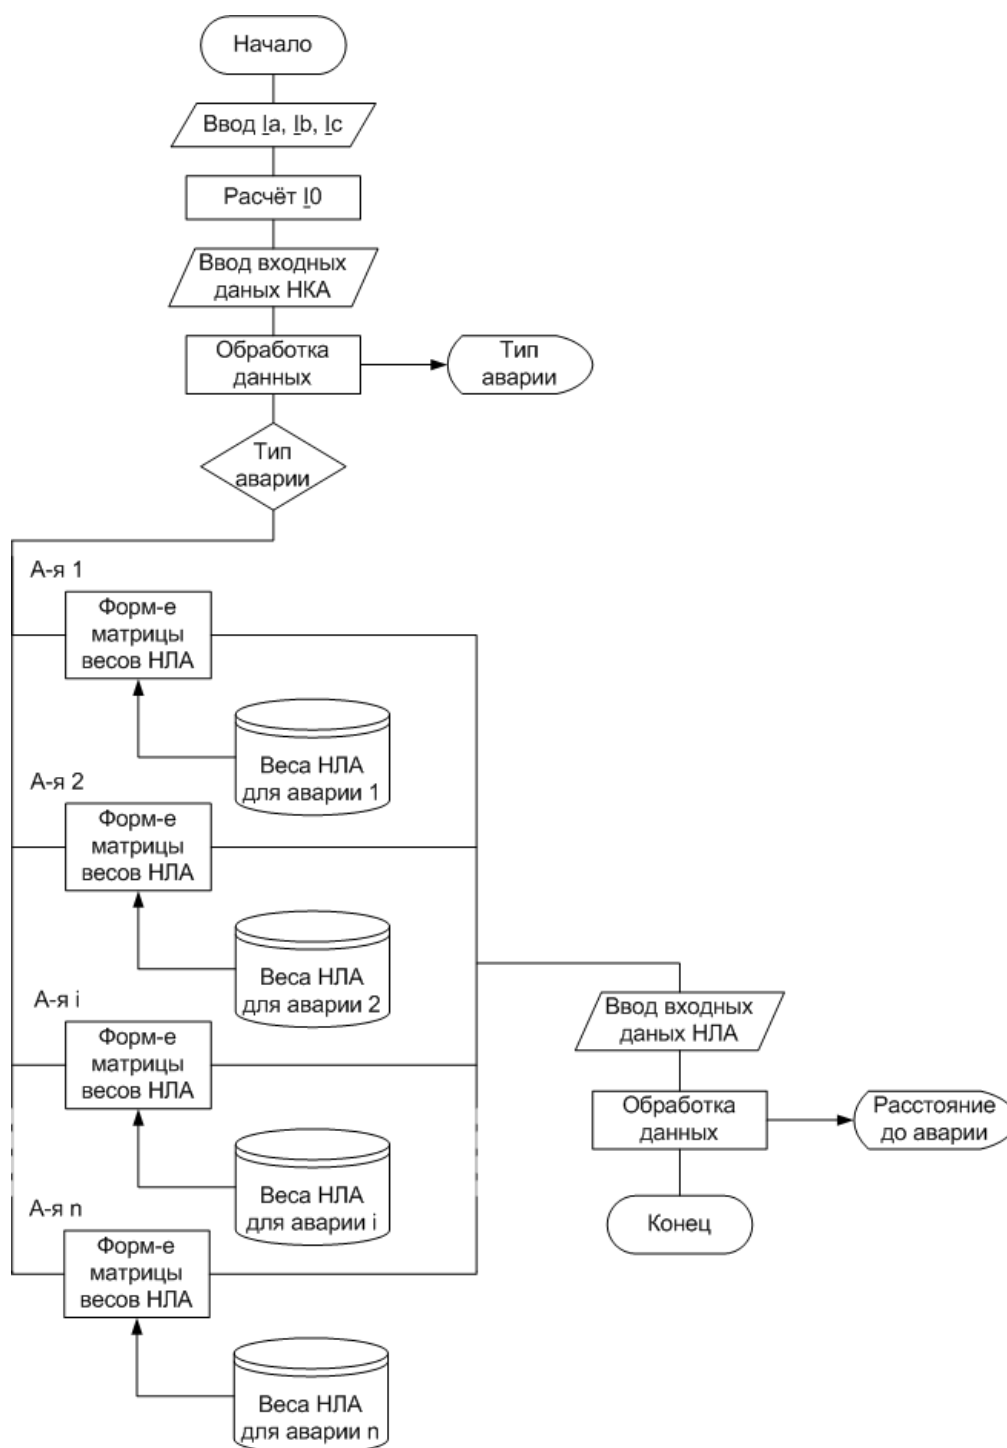


Рис. 6.10. Алгоритм функционирования адаптивной информационно-измерительной системы

ЗАКЛЮЧЕНИЕ

Возникновение нейросетевых технологий, обладающих уникальными функциональными возможностями обработки информации, во многом обязано тем успехам, которые достиг человек в естествознании на рубеже XIX-XX вв. Основоположник биологии как науки, французский учёный Жан Батист Ламарк, не раз отмечал первостепенную важность изучения человеком природы: «Из всех знаний наиболее полезно для нас знание природы, её законов, словом, – всех её деяний при всякого рода обстоятельствах» [9]. По мнению авторов, выдвинутый Ламарком постулат об особой «полезности» знаний об окружающем мире, подтверждается тем, что по мере развития естествознания у человека появляется возможность воплощать в технической отрасли на всё более высоком уровне «природные» технологии: начиная от механических античных устройств, копирующих лишь движения человека и животных, и заканчивая нейрокомпьютером, воспроизводящем процесс мышления.

Следует отметить, что технология искусственных нейронных сетей возникла как плод совместной деятельности двух учёных – физиолога и математика, отразив тем самым намечавшуюся в XX в. тенденцию к «смыканию» наук, о чём писал В.И. Вернадский [9]. Продолжение этого тренда отчётливо наблюдается в первой половине XXI века, а значит, успехи в изучении принципов работы головного мозга человека неизбежно приведут к возникновению более совершенных моделей нейросетей. Таким образом, по словам философа Дэвида Чалмерса, вполне реальным может оказаться сценарий, при котором у искусственной нейронной сети появится способность к сознанию: «Признав удивительным факт порождения мозгом сознания, мы не испытаем нового удивления, обнаружив, что вычисление могло бы порождать сознание» [21].

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Кизим Н. А., Ястремская Е. Н., Сенчуков В. Ф. Нейронные сети: теория и практика применения : монография. – Х.: ИНЖЭК, 2006. – 240 с.
2. Боровиков В. STATISTICA; искусство анализа данных на компьютере. Для профессионалов. – СПб.: Питер, 2001. – 656 с.
3. Бондарев В. Н. Искусственный интеллект / В. Н. Бондарев, Ф. Г. Аде. – Севастополь : Изд-во СевНТУ, 2002. – 616 с.
4. Калан Р. Основные концепции нейронных сетей. – М.: Вильямс, 2001. – 288 с.
5. Круглов В. В., Борисов В. В. Искусственные нейронные сети. Теория и практика. – М.: Горячая линия; Телеком, 2002. – 382 с.
6. Медведев В. С., Потемкин В. Г. Нейронные сети (MATLAB 6). – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.
7. Нейронные сети. STATISTICA Neural Networks : пер. с англ. – М.: Горячая линия – Телеком, 2002. – 182 с.
8. Комарцова Л. Г., Максимов А. В. Нейрокомпьютеры. – М.: Изд-во МГТУ им. Н. Э. Баумана, 2002. – 320 с.
9. Карако, П. С. Философия и методология науки : В.И. Вернадский. Учение о биосфере / П. С. Карако. – Минск : Экоперспектива, 2007. – 208 с.
10. Емельянов-Ярославский, Л. Б. Интеллектуальная квазибиологическая система. Индуктивный автомат / Л. Б. Емельянов-Ярославский. – М.: Наука, 1990. – 112 с.
11. Круглов, В. В. Искусственные нейронные сети. Теория и практика / В. В. Круглов, В. В. Борисов. – 2-е изд. – М.: Горячая линия – Телеком, 2002. – 382 с.
12. Осовский, С. Нейронные сети для обработки информации / Станислав Осовский ; пер. с пол. И. Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.
13. Орфеев, Ю. В. Мышление человека и искусственный интеллект / Ю. В. Орфеев, В. С. Тюхтин. – М.: Мысль, 1978. – 149 с.
14. Нейронные сети. STATISTICA Neural Networks : пер. с англ. – М.: Горячая линия – Телеком, 2001. – 182 с.
15. Masters, T. Practical neural network recipes in C++ / T. Masters. – Boston : Academic Press Inc, 1993. – 494 p.
16. Попов, Е. П. Роботы и человек / Е. П. Попов, А. С. Ющенко. – М.: Наука, 1984. – 112 с.
17. Руднев, В. А. Применение микроконтроллеров для реализации нейронных сетей / В. А. Руднев // Вестн. Юж.-Уральск. гос. ун-та. Сер. Компьютерные технологии, управление, радиоэлектроника. – 2012. – Вып. 16, № 23. – С. 181–183.
18. Основные характеристики ветра. Ресурсы ветра и методы их расчета : учеб. пособие / Г. В. Дерюгина [и др.]. – М.: МЭИ, 2012. – 260 с.
19. Уоссерман, Ф. Нейрокомпьютерная техника. Теория и практика / Филипп Уоссерман ; пер. с англ. Ю. А. Зуева, В. А. Точенова. – М.: Мир, 1992. – 237 с.
20. Obisesan, T. Neural network learns to diagnose congenital cataracts [Электронный ресурс] / T. Obisesan // Medgadget. – Режим доступа : <https://www.medgadget.com/>

2017/02/neural-network-learns-diagnose-congenital-catracts.html. – (Дата обращения : 10.09.2020).

21. Чалмерс, Д. Сознательный ум. В поисках фундаментальной теории / Дэвид Чалмерс ; пер. с англ. В. В. Васильева. – М.: Либроком, 2015. – 512 с.

22. Шумский, С. А. Нейросетевые агенты в интернете / С. А. Шумский // Компьютерра. – 2000. – № 4. – С. 20–22.

23. Ясницкий, Л. Н. Введение в искусственный интеллект : учеб. пособие для студ. высш. учеб. заведений / Л. Н. Ясницкий. – 2-е изд., испр. – М.: Академия, 2008. – 176 с.

Учебное издание

Сергей Валерьевич **Макартичан**
Надежда Сергеевна **Кузнецова**
Сергей Сергеевич **Дементьев**

**НЕЙРОННЫЕ СИСТЕМЫ
ОБРАБОТКИ ИНФОРМАЦИИ**

Учебно-методическое пособие

Редактор *Л. Н. Рыжих*