

Министерство образования Российской Федерации
Владимирский государственный университет

В.Н. ГОРЛОВ

ПРИКЛАДНЫЕ НЕЙРОКОМПЬЮТЕРНЫЕ СИСТЕМЫ

Учебное пособие

Владимир 2003

УДК 681.31: 612.822

Г69

Рецензенты:

Доктор физико-математических наук, профессор,
зав. кафедрой математического анализа

Владимирского государственного педагогического университета

В.В. Жиков

Кандидат технических наук, доцент кафедры информатики

Всероссийского заочного финансово-экономического

института (г. Владимир)

А.А. Левкин

Печатается по решению редакционно-издательского совета

Владимирского государственного университета

Горлов В.Н.

Г69 Прикладные нейрокомпьютерные системы: Учеб. пособие / Владим.
гос. ун-т. Владимир, 2003. 128 с.

ISBN 5-89368-389-7

Посвящено одному из современных направлений в области информатики и вычислительной техники – нейрокомпьютерным технологиям. Рассмотрены вопросы теории искусственных нейросетей, большое внимание уделено программным имитационным моделям нейронных сетей, а также решению с их помощью практических задач распознавания образов, идентификации, оптимизации.

Предназначено для студентов четвертого курса специальности 010200 – прикладная математика и информатика, изучающих курсы «Базы данных и экспертные системы» и «Методы оптимизации управления». Может быть использовано в лекционных курсах студентами специальностей, связанных с подготовкой специалистов по вычислительной технике, – 220100, 220200, 220300 и 220400.

Табл. 2. Ил. 47. Библиогр.: 30 назв.

УДК 681.31: 612.822

© Владимирский государственный
университет, 2003

ISBN 5-89368-389-7

Предисловие

В настоящем учебном пособии предпринята попытка кратко изложить основные понятия и методы моделирования нейронных сетей, а также показать возможности применения нейрокомпьютерной техники для решения практических задач. Нейрокомпьютеры олицетворяют собой новую технологию обработки информации, связанную с переходом на принципиально новый нейросетевой логический базис. Это является объективной причиной резкого повышения отношения производительности к стоимости при решении сложных задач и, как следствие, причиной появления принципиально новых задач, которые ранее не решались.

Искусственные нейронные сети строятся по принципу организации и функционирования их биологических аналогов. Определение многослойных нейронных сетей было впервые введено Ф. Розенблаттом в его классической работе [23] и более ранних его работах и понимается как особое свойство структуры преобразования, осуществляемого разомкнутой нейронной сетью при топологическом, а не символическом описании. Базовыми понятиями теории нейронных сетей являются:

- входной и выходной сигналы;
- желаемый выходной сигнал;
- функционалы первичной и вторичной оптимизации;
- алгоритмы поиска экстремума функционала вторичной оптимизации как алгоритмы адаптивного управления в нейронных сетях.

В настоящее время регулярно публикуются аналитические материалы, обобщающие результаты разработок и внедрения нейрокомпьютеров. Анализ этих работ показывает принципиальное различие подходов к решению задач при использовании последовательных электронно-вычислительных машин (ЭВМ) и нейрокомпьютеров. При решении задач с помощью обычных последовательных ЭВМ разработка систем включает сложные этапы

исследования специфики предметной области, создания алгоритмов, моделирования, проверки релевантности моделей и многочисленные опыты по принципу проб и ошибок. Использование нейронных сетей позволяет автоматизировать все эти процессы.

Представим некоторые проблемы, решаемые искусственными нейронными сетями.

Классификация образов. Задача классификации образов состоит в определении принадлежности входного образа, представленного вектором показателей, одному или нескольким классам. К таким задачам относятся, например, распознавание букв и речи, классификация сигналов электрокардиограммы, классификация клеток крови.

Аппроксимация функций. Предположим, что задана обучающая выборка $((x_1, y_1), (x_2, y_2), \dots, (x_N, y_N))$, которая генерируется неизвестной функцией, искаженной шумом. Задача аппроксимации состоит в нахождении оценки этой функции.

Прогноз. Заданы N дискретных отсчетов $\{y(t_1), y(t_2), \dots, y(t_N)\}$ в последовательные моменты времени t_1, t_2, \dots, t_N . Требуется предсказать значение $y(t_{N+1})$ в момент t_{N+1} . Прогноз имеет значительное влияние на принятие решений в бизнесе, науке, технике.

Оптимизация. Многочисленные проблемы в математике, статистике, технике, науке, медицине, экономике могут рассматриваться как проблемы оптимизации. Задачей оптимизации является поиск решения, которое удовлетворяло бы систему ограничений и максимизировало или минимизировало бы целевую функцию.

Ассоциативная память. В современных вычислительных системах обращение к памяти доступно только посредством адреса, который не зависит от содержания памяти. Более того, если допущена ошибка в вычислении адреса, то может быть найдена совершенно иная информация. Память, адресуемая по содержанию, или ассоциативная память, доступна по указанию заданного содержания (ключевого образа). Содержимое памяти может быть воспроизведено даже по частичному или искаженному образу.

Разработка и применение ассоциативной памяти является чрезвычайно актуальной задачей при создании перспективных информационно-вычислительных систем.

Учебное пособие условно (по смыслу) можно разделить на 3 части. В первой – рассматриваются биологические нейронные сети и их структурная организация (гл. 1 – 2), во второй (гл. 3) – вопросы теории искусственных нейронных сетей, в третьей (гл. 4) приведены конкретные примеры применения нейросетевого подхода для решения практических задач.

Несмотря на большой интерес, проявляемый к нейросетевым технологиям, учебная литература по этому направлению в нашей стране издается малыми тиражами. Целью настоящего учебного пособия в связи с этим является знакомство студентов вузов с основными понятиями, методами исследования и применения нейронных сетей.

Автор выражает благодарность студентам М. Соколову (гр. РМ-201) и Р. Батаеву (гр. ПМ-299). Первый разработал алгоритм и программу определения оптимального порога активизации нейронов, второй – интерфейс компьютерной модели нейронного постоянного запоминающего устройства. Результаты этих исследований автор использовал в данной работе.

Глава 1. БИОЛОГИЧЕСКИЕ НЕЙРОННЫЕ СЕТИ

1.1. Структурная организация нейронных сетей

Нервные системы биологических организмов состоят из огромного количества нервных клеток различных типов, которые организованы в сеть. Огромное количество элементов, запутанность и многочисленность связей исключают в настоящее время возможность выявить реальную схему сложных нервных образований. Вместе с тем имеющиеся данные дают некоторые представления об организации нейронных сетей, выполняющих функции переработки и хранения информации.

Имеющиеся результаты экспериментальных исследований дают основания допускать однородность отдельных участков нервной системы. Представления об однородности могут быть с успехом распространены на некоторые более или менее стабильные по функциональной организации участки нервной системы, предназначенные для обработки параллельно идущего по многим волокнам и в среднем однородного потока информации. Вероятно, к числу таких участков нервной системы можно отнести некоторые периферические отделы анализаторных систем. Однородность строения свойственна и коре мозжечка, включающей высшие и новейшие функции мозга. Данная черта конструкции обусловлена, в свою очередь, тем, что кора мозжечка в отличие от коры большого мозга работает как бы в одном плане, т.е. на всем своем протяжении осуществляет сходную функцию анализа и синтеза одного общего комплекса раздражителей.

Если ограничить рассмотрение высшими уровнями центральной нервной системы, где, вероятно, локализованы память и высшие функции обработки информации, то там, как установлено, нейроны образуют слоистые структуры (различные типы ядер, серое вещество). Послойная структура, имеющая, по-видимому, иерархический смысл в структурном и функциональном отношении, является одной из наиболее важных особенностей нервной организации. Представление об иерархической организации нервных центров настолько очевидно, что считается тривиальным:

спинной мозг, нижний отдел ствола, верхний отдел ствола и кора. В сенсорных путях также существуют рецепторный уровень, несколько уровней анализа признаков, уровень подкорковых ядер и несколько кортикальных уровней. Сходные формы послойной организации нейронных сетей наблюдаются во многих областях нервной системы. Наиболее яркими примерами подобной организации у позвоночных являются сетчатка и гиппокамп. Кора головного мозга имеет также многослойную структуру и состоит в основном из шести структурных слоев, зрительное поле коры состоит из четырех структурно и функционально различных слоев.

Основное тело нервной клетки, называемое сомой, содержит внутриклеточные компоненты, являющиеся общими для большинства клеток: ядро и различные клеточные компоненты, необходимые для обмена веществ и синтеза белков. Внутриклеточная жидкость – цитоплазма – вместе с другими частицами заполняет все части клетки.

Нейрон должен иметь сигнальные контакты с множеством других нейронов (рис. 1.1), поэтому внешняя клеточная мембрана обычно имеет встроенные ответвления, называемые дендритами.

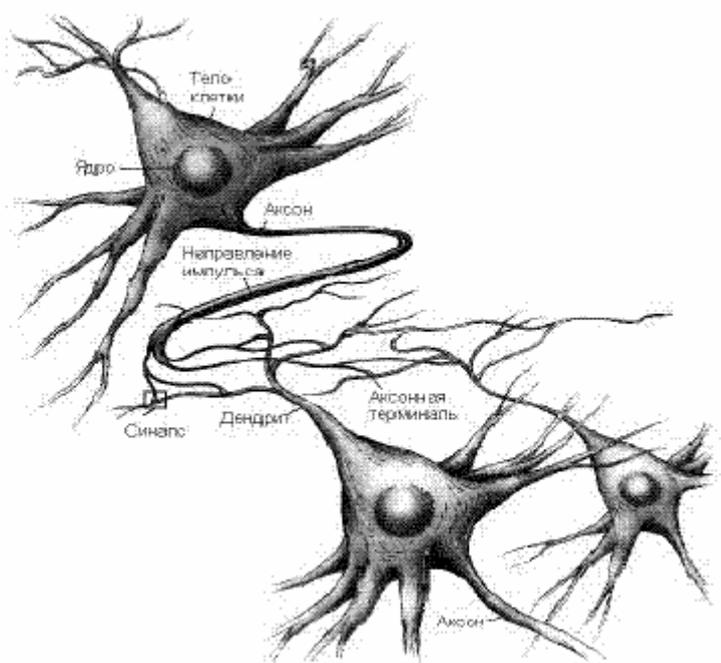


Рис. 1.1. Биологический нейрон

В некоторых клетках дендриты образуют почти звездную структуру. Очень важный тип клеток – пирамидальные клетки (рис. 1.2), которые

имеют два набора дендритов. Апоикальные дендриты наиболее удалены от сомы и связаны с ней лучевыми вытяжками мембраны. В основании пирамидальной сомы находится другой набор ответвлений – базальные или базиллярные дендриты.

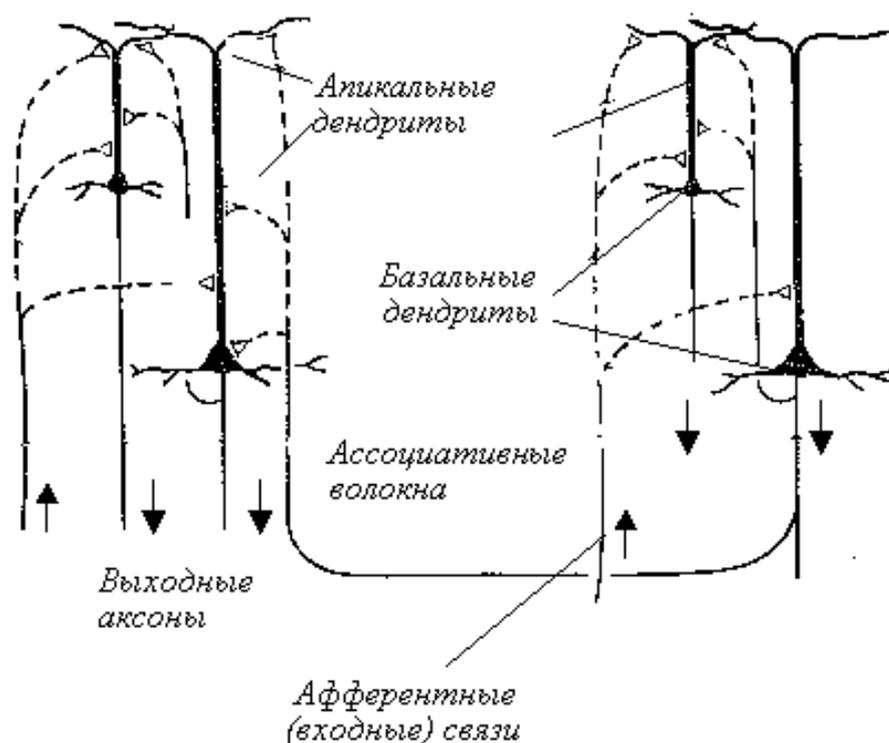


Рис. 1.2. Упрощенная схема центрального неокортекса

На рис. 1.2 показано сечение церебрального неокортекса, образующего основную часть мозга человека. Большинство клеток (пирамидального типа) обеспечивают передачу сигналов в направлении сверху вниз. Нейрон посылает сигналы другим нейронам по выходному волокну – аксону. Внешний сигнальный вход в кору головного мозга осуществляется через выходные аксоны других клеток, связанных с ней либо непосредственно, либо через небольшие промежуточные клетки – интернейроны. Через аксоны пирамидальные клетки устанавливают связи с другими нейронами.

Пирамидальные клетки имеют связи также и в поперечном направлении. Внутри коры для этого используются коллатеральные ответвления выходных аксонов, причем связи организованы либо непосредственно, ли-

бо посредством интернейронов. В коре головного мозга человека эти интракортикальные связи могут достигать длины в 2 – 3 мм. На более длинных расстояниях, достигающих нескольких сантиметров, взаимные связи, как правило, осуществляются посредством внешних аксонов пирамидальных клеток, которые и образуют хорошо известное белое вещество мозга (эти связи называются субкортикальными). Таким образом, все связи коры можно разделить на параллельные, проходящие сверху вниз, и поперечные.

Нейронная структура мозжечка – органа координации движений – приведена на рис. 1.3. Наиболее важными клетками мозжечка являются клетки Пуркинье, имеющие много входных дендритных ответвлений, собранных в тонкие листки, пространственно разделенные между собой не нейронными клетками. Клетки Пуркинье имеют две группы входных волокон. Прежде всего обычно имеется один специфический вход в каждую клетку, называемый входящим волокном; очевидно, эти волокна передают какую-то важную информацию. Другой вход проходит через так называемые параллельные волокна, которые пронизывают листки в перпендикулярном направлении. Следует отметить, что помимо коры головного мозга и мозжечковой коры мозг состоит из многих других частей, которые здесь не рассматриваются. Задача состоит лишь в том, чтобы подчеркнуть наличие в мозге сетевых структур. Ниже будет рассмотрена структура и функциональные свойства элементов сети.

Характерной особенностью организации мозга является то, что соединенные между собой элементы нейронной сети располагаются во взаимно перпендикулярных плоскостях. Дендритные разветвления распространяются преимущественно в поперечном направлении волокон, которые ориентированы главным образом в продольном направлении. Тем самым достигается более полная реализация функциональных возможностей.

Имеются экспериментальные данные, указывающие на преобладание вертикальных связей не только входящих и выходящих волокон, но также связей между нейронами внутри коры. Вместе с тем боковые связи, проходящие в верхней пластинке (при тангенциальных разрезах на коре), свидетельствуют о тесном взаимодействии соседних элементов. При исследовании соматической проекционной зоны у мышей были обнаружены «бочонки» из клеток, идущие вертикально по IV слою. Полость «бочонков» содержала волокна и почти не содержала клеток; стенки, напротив, были за-

полнены клетками. В результате было сделано предположение, что такие «бочонки» представляют собой структурный элемент функциональных колонок, который виден в этой сравнительно примитивной коре, но маскируется в сложной цитоархитектонике более развитой коры других видов животных.

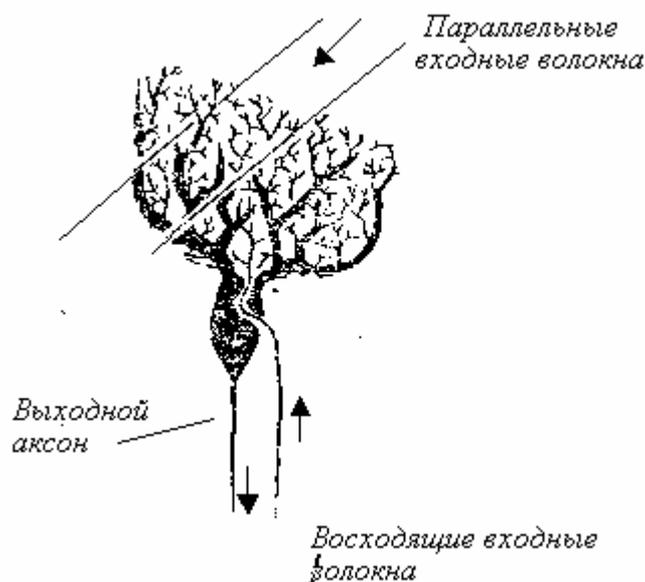


Рис. 1.3. Клетки Пуркинье в мозжечке

Различные корковые поля и пункты коры связаны при помощи ассоциативных связей и могут тесно взаимодействовать и обмениваться между собой информацией. Помимо уже упомянутых выше вертикальных и внутренних коротких боковых связей нейронов, в самом наружном слое коры головного мозга параллельно ее поверхности проходят ответвления аксонов и дендритов. Их очень много, но они идут на небольшие расстояния, и если прервать их перекрестными разрезами с промежутками около 1 мм, то это лишь незначительно повредит функции мозга. Следовательно, эти связи, по-видимому, предназначены только строго для местных нужд, в масштабе долей миллиметра. Более длинные связи осуществляются по U-образным волокнам, т.е. по аксонам, которые уходят в белое вещество, а затем на некотором расстоянии снова появляются на поверхности. Афферентный приток в кору осуществляется с помощью волокон таламической радиации. Активность, выходящая из коры, проводится по волокнам, кото-

рые проходят примерно параллельно входящим, но в обратном направлении, и затем распределяются между таламусом, базальными ганглиями, мозговым стволом и спинным мозгом.

В процессе усложнения аналитико-синтетической деятельности в системах анализаторов выделяются наряду с относительно короткими и прямыми путями переключения импульсов более длинные цепи нейронов с большим числом промежуточных переключений, соединяющие элементы воспринимающей поверхности с периферическими полями ядерных зон анализаторов в коре. При такой конструкции сигналы, посылаемые из одной и той же точки воспринимающей поверхности анализаторной системы, могут достигать разных точек коры, а к одной и той же точке коры конвергируют сигналы от разных точек воспринимающей поверхности. Благодаря такой организации взаимосвязей осуществляются разнообразные формы интеграции тонко дискриминируемых сигнальных раздражителей.

Нейронная сеть, образующая мозг, в общем состоит, как известно, почти полностью из ассоциативных нейронов и служит для переработки и хранения информации. На вход сети поступает информация от сенсорных нейронов, выход соединен с моторными нейронами, на которые сеть выдает управляющие сигналы в зависимости от полученного результата переработки поступившей информации.

Говоря о распределении клеток разных типов и связей между ними, следует отметить следующее. Для клеток коры головного мозга характерно, что к каждой такой клетке приходят связи примерно от сотен и тысяч других клеток, которые могут быть рассеяны в широкой области, но выход этой клетки, по-видимому, связан с относительно четко локализованным участком. Клетки, на которые приходят входные сенсорные сигналы, как правило, связаны с ограниченной областью источников сигналов на сенсорных поверхностях, таких как сетчатка или кожа. В нейронной сети синаптическая связь между двумя нейронами реализуется обычно несколькими контактами. Но не исключены случаи, когда между нейронами имеется всего лишь один синаптический контакт. При моделировании обычно принято считать, что так как синаптические бляшки от одного нейрона соединены параллельно и каждая вносит в тело клетки некоторую активность, то их можно заменить одной и присвоить данному входу весовой коэффициент. Однако следует иметь в виду, что это справедливо при близком расположении синапсов друг к другу.

Аксо-дендритические синапсы преимущественно являются возбуждающими, а аксо-самотические – тормозящими. Большинство нейрофизиологов считают, что существуют специфические тормозящие пути и тормозные нейроны. Например, вставочные нейроны оказывают исключительно тормозящее влияние.

Имеются данные, что в нейронной сети существуют синаптические контакты также между аксонами различных нейронов, причем иногда расположенные далеко от тела клетки. Концевые бляшки двух различных аксонов помимо образования синапсов на теле или дендритах нейрона могут иметь контакт между собой, причем допускается возможность двусторонней передачи в таких синапсах. Между аксонами наблюдается также взаимодействие следующего вида: концевая бляшка одного волокна образует синапс на бляшке другого волокна и влияет на его работу. Это влияние (пресинаптическое торможение) является односторонним, имеет в основном тормозящий характер и действует как клапан – выключает только то, что поступает через определенное эфферентное окончание, представляя всем остальным возможность проводить возбуждение. Постсинаптическое торможение на теле клетки действует как общий тормоз: оно противодействует возбуждению из любого источника. Под воздействием приходящих сигналов мембранный потенциал клетки колеблется, меняя поток выходных импульсов. Таким образом, импульсный код пресинаптических волокон преобразуется в аналоговый сигнал в синапсе, а затем после обработки в нейроне вновь превращается в импульсный код в аксоне постсинаптической клетки. Все предварительные логические операции производятся в синапсе по аналоговому принципу, более сложная обработка информации производится в самом нейроне. Мозг в своей деятельности широко использует как дискретный, так и аналоговый принцип обработки информации, и, по-видимому, механизм обработки обоих типов предопределен генетически.

Одним из характерных свойств мозга как нейронной сети является определенная пластичность локализации в «ассоциативных областях» в противоположность относительно фиксированному и неподвижному характеру сенсорных и моторных трактов. Потеря функции, связанная с нарушением в ассоциативной области коры, скорее всего носит характер временного повреждения, и после некоторого периода переадаптации данная функция начинает выполняться соседними участками. Установлено, что даже в этом случае локализация не является жесткой и абсолютной, что

существует некоторая гибкость, позволяющая соседним участкам принимать на себя функции поврежденной ткани. Области сенсорной проекции, по-видимому, невозможны для восприятия.

Имеется много данных, позволяющих предположить, что свойства пластичности нейронных сетей связаны со статистическим характером закономерностей поведения нейронов и вероятностным способом их участия в процессах нервной деятельности. Уже давно высказывались теоретические предположения о функциональных объединениях популяций нервных клеток в гипотетические конstellации, или ансамбли, и даже показан возможный нейрофизиологический механизм образования таких объединений путем цепных реакций. Групповой характер нейронной структуры согласуется с существующими вертикальными нейронными колонками (в пределах одного слоя). Эти данные дают основание предположить, что свойства приспособительной живучести нервных механизмов обусловлены особенностью принципов их конструкции как статистической организации вероятностных ансамблей нейронов.

Использование этих принципов вытекает из исключительной многоэлементности нервных механизмов управления, что делает практически невозможным обеспечение надежного детерминизма их деятельности на основе однозначности реакций каждого колоссального множества нервных клеток. Следует заметить, что при многослойной организации живых нейронных сетей связи в пределах каждого горизонтального слоя являются случайными, однако связи между слоями – детерминированными.

В нейронной сети большое количество нейронов находятся в состоянии постоянной импульсной активности. Для клеток различных отделов характерен свой рисунок – паттерн спонтанной (фоновой) активности. При этом нейрон может либо сам создавать ритм, либо наблюдаемое движение может порождаться повторно самовозбуждающимися или реверберирующими цепями (называемыми также положительной обратной связью). Кроме того, фоновая импульсация существует и за счет постоянно поступающих в сеть сигналов рецепторных клеток от внешних раздражителей. Это подтверждается опытами, в которых при изоляции мозга от раздражения импульсацией, поступающей от афферентных путей или непосредственно от поверхности мозга, фоновая активность резко снижена.

Установлено, что фоновая активность, а также фиксация и удержание индивидуально выработанных следов раздражения, свойственны даже

нейронально изолированной коре. Отсюда можно сделать вывод о существовании в коре, т.е. в нейронной сети, собственных, непосредственных подкорковыми влияниями механизмов функциональной интеграции, обеспечивающих удержание выработанных следов памяти.

В реальных нейронных сетях, как уже отмечалось выше, передача возбуждения, включение регулирующих тормозных и возбуждающих влияний, управление системными процессами обеспечиваются функционально связанными совокупностями нейронов, нейронными ансамблями. Надежное возникновение хотя бы одного импульса в данный короткий момент времени может быть обеспечено ансамблем, состоящим не менее чем из 100 однородных единиц. Зависимость между обучаемостью и мощностью популяции, определяемой по частоте импульсации и числу единиц, нелинейна. В принципе при наличии больших клеточных масс нейронная сеть имеет большие возможности для формирования сложных межклеточных связей, которые и составляют морфологическую основу обучения.

Одним из общих принципов работы нейронных сетей является принцип латерального (бокового) торможения.

Механизм латерального торможения был особенно тщательно исследован применительно к сенсорным системам и, в частности, к зрению, где латеральное торможение использовалось для повышения контраста. Это явление особенно ярко выражено в сетчатке глаза, однако оно может иметь место и в других нейронных системах. Результаты экспериментальных исследований показывают, что, как правило, возбуждающий входной сигнал приводит к уменьшению активности соседних клеток в неокортексе. Этот эффект проявляет свое максимальное действие на расстоянии 100 – 200 мкм от точки воздействия или стимуляции. Механизм латерального торможения детально изучен для сетчатки, однако для высших систем головного мозга происхождение этого явления в значительной мере неясно. Иногда его связывают с короткодействующими тормозящими межнейронными соединениями, которые существенно отличны от далекодействующих соединений. Однако вполне возможно, что латеральное торможение осуществляется не за счет прямой синаптической передачи сигнала на короткие расстояния, а благодаря электрическому взаимодействию между мембранами, или несинаптическому химическому эффекту. Каким бы ни был механизм латерального торможения, важно, что эффект реально существует и может быть весьма точно измерен. На рис. 1.4 показан график,

представляющий зависимость степени активности клеток от расстояния; можно заметить, что на расстоянии в пределах 100 мкм (от точки стимуляции до точки наблюдения) влияние оказывается стимулирующим, однако вне указанной области влияние является тормозящим (отрицательное значение «возбуждения»). На более далеких расстояниях должен существовать небольшой стимулирующий эффект, обусловленный подкорковыми межнейронными связями.

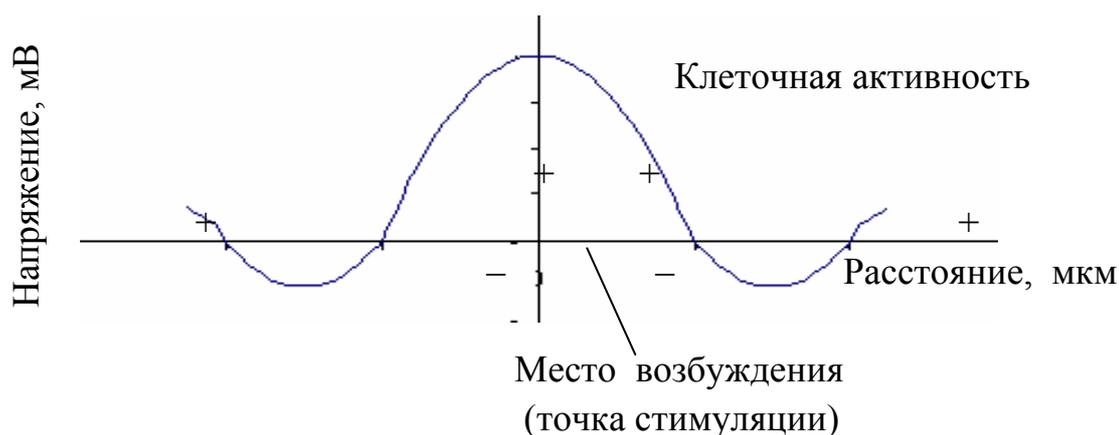


Рис. 1.4. Латеральное распространение возбуждения (или торможения) в нейронной сети

Латеральное торможение обнаружено не только в сетчатке глаза позвоночных, но и в слуховой системе, в системе осязания и др. Оно, видимо, играет существенную роль не только в функционировании органов чувств, но и в ряде других явлений. Так, например, группы нейронов, близко расположенные друг к другу и имеющие сходные функции, проявляют тенденцию к синхронизации, но в ряде случаев такая синхронизация может быть крайне нежелательна. Было высказано предположение, подтвержденное затем вычислительными экспериментами на ЭВМ, что тормозное влияние каждого из нейронов, входящих в данную группу, на все остальные нейроны может быть десинхронизирующим и тем самым обеспечивать возможность заданного плавного изменения той или иной величины (например напряжения мышцы), передаваемой с помощью нервных импульсов, исходящих от некоторого нейронного ансамбля.

Приведенные примеры не исчерпывают функциональные возможности латеральных тормозных связей, которые играют фундаментальную роль в работе многих отделов нервной системы.

Центральный вопрос нейронной организации высших анализаторных механизмов состоит в том, что афферентные нейроны образуют сложнейшие функциональные мозаики, в которых осуществляются кодирование и обработка информации, поступающей от рецепторов.

Для изучения такой организации важное значение имеет понятие рецептивного поля. На примере кожного анализатора рецептивное поле можно определить как зону кожной поверхности, иннервируемую одним афферентным волокном. Исследования реакций корковых нейронов на раздражения, захватывающие различные участки поля рецепторов, показали, что каждый нейрон конвергирует импульсы от определенной группы рецепторов. Характер, размеры и конфигурация их рецептивных полей оказались весьма различными в соматосенсорном, слуховом и других анализаторах. Эти различия отражают особенности их организации и свойств центральных нейронов как сумматоров сигналов, поступающих от предыдущих уровней афферентных путей. При этом были выявлены изменения характеристик рецептивных полей, свидетельствующие об осуществлении более простых видов анализа на более ранних уровнях афферентации. Благодаря такому предварительному анализу происходит «фильтрация деталей», и на высшие уровни проекционных полей пропускается лишь наиболее содержательная, обобщенная информация.

Особого внимания как существенный механизм анализа заслуживает организация перекрытий рецептивных полей, связанных со специализацией соответствующих нейронов. Так, например, нейроны соматосенсорной коры с ограниченными и распространенными рецептивными полями различаются и другими своими свойствами, одним из которых является характер пульсации. Рецептивные поля могут изменять свои размеры в зависимости от взаимодействия возбуждательных и тормозных влияний, обуславливающих результирующую реакцию нейрона.

Таким образом, принципы организации локальных рецептивных полей, из взаимодействия в перекрытиях и отношения по типу бокового торможения лежат в основе функциональной организации нейронной сети проекционных структур и определяют формирования их мозаик, в которых кодируется и обрабатывается сенсорная информация.

В заключение следует отметить, что при моделировании нейронных сетей необходимо осторожно относиться к их формализации, так как отвлечение от ряда, на первый взгляд, второстепенных структурных или

функциональных признаков организации может повлечь за собой коренное качественное изменение функционирования нейронной сети, вплоть до ее полной неработоспособности или невозможности выполнения требуемых функций.

1.2. Организация сигнальных связей между нейронами

Анализ новейших исследований позволяет утверждать, что основная функция нервной клетки состоит в усилении сигналов. Вместе с тем нейрон выполняет и функции обработки информации. Каждый нейрон связан с большим количеством других нейронов – порядка нескольких тысяч в пирамидальных клетках, и до 10^5 сигналов поступают в клетки Пуркинье. Существуют также и нейроны, имеющие лишь несколько сотен входов. Каждая клетка имеет один выход, который может разветвляться за счет коллатеральных связей. В настоящее время не совсем ясно, в какой мере нервную клетку со многими входами и одним выходом допустимо рассматривать хотя бы с системно-теоретической точки зрения как логическую схему, и в какой мере – как аналоговое вычислительное устройство. В данной работе будем рассматривать нейроны как логические схемы. Нейронные сигналы передаются в виде серий электрических импульсов, распространяющихся по выходным волокнам – аксонам – в виде своеобразных волновых фронтов. Не рассматривая в деталях механизм этого явления, отметим, что клеточная мембрана биофизически активна. В частности, за счет селективной диффузии ионов между внешней и внутренней сторонами тубулярной мембраны создается электрический потенциал порядка 70 мВ. С помощью специальных химических добавок можно повысить проницаемость мембраны; то же самое можно сделать путем ее электрического возбуждения. Усиленная диффузия ионов деполяризует мембрану. В результате проницаемость снова увеличивается. Таким образом, существует позитивная (регенеративная) обратная связь, с помощью которой мембранный потенциал и характеристики диффузии ионов натрия, калия и хлора динамически изменяются с генерацией электрических импульсов, имеющих амплитуду около 100 мВ и продолжительность около 0,5-2,0 мс. Импульсы генерируются в области соприкосновения аксона и клеточного тела, называемой аксонным холмиком. Скорость распространения импульсов вниз по аксону изменяется от 0,5 до 100 м/с в зависимости от диаметра аксона и природы покрывающей его ткани.

Сигналы распространяются от нейронных аксонов к дендритам или к соме других нейронов по специальным структурам, называемым синапсами (рис. 1.5). Каждый аксон имеет синаптическое окончание, или терминаль, которое способно освобождать химические вещества, называемые медиаторами. Известны различные типы медиаторов, однако каждый нейрон обладает своим специфическим медиатором. Нейронный импульс приводит к освобождению из терминали некоторого количества медиатора, который, преодолевая небольшой зазор, достигает мембраны приемной (постсинаптической) клетки. Вещество медиатора в состоянии возбудить мембрану, однако процесс возбуждения оказывается значительно более эффективным за счет действия специальных белков – химических рецепторов, расположенных на постсинаптической мембране.

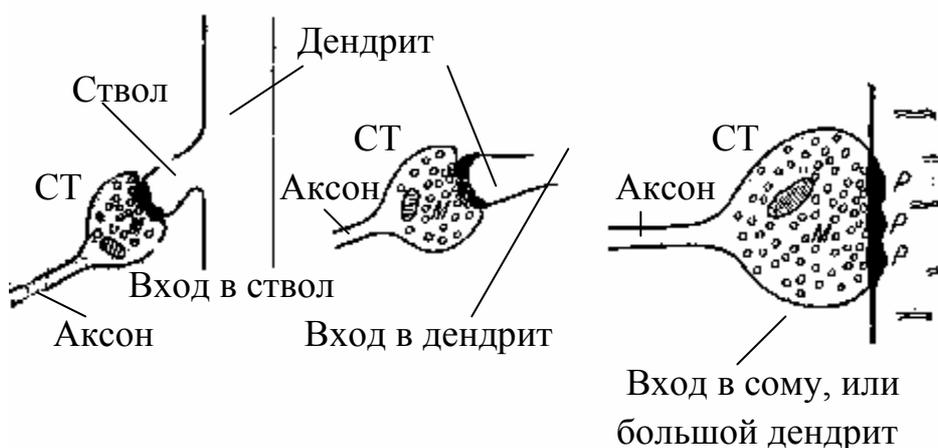


Рис. 1.5. Различные типы синаптических соединений (синапсов)
СТ – синаптическая терминаль; Р – химические рецепторы

Таким образом, в результате комбинированного действия медиаторов и рецепторов электрический потенциал постсинаптической мембраны изменяется на небольшую величину. Поскольку имеется большое количество входов, потенциал мембраны постепенно изменяется, достигая (в области аксонного холмика) порогового значения; это приводит к генерации импульса. Если воздействие медиаторов и рецепторов непрерывно и эффективно, то нейрон генерирует непрерывный ряд выходных импульсов, которые могут способны возбуждать другие нейроны.

Таким образом, передача и усиление сигналов представляют собой в основном электрохимические процессы, однако одновременно с ними про-

исходят и некоторые биофизические явления. В связи с ограниченным объемом данной работы не рассматриваются подробности строения и функционирования синапсов и связей. Однако с математической точки зрения представляется весьма важным знание закона, описывающего зависимость выходных импульсов от параметров процесса воздействия медиаторов и рецепторов на мембрану клетки. С учетом новейших исследований с приемлемой точностью можно считать, что эффекты воздействия различных синапсов на мембранный потенциал суммируются линейно. Однако отдельные синапсы могут иметь различные веса (или эффективность) в отношении передачи сигналов, причем веса зависят от размеров синапсов, а также (видимо, в большей степени) от количества рецепторов. В настоящее время различают два типа синапсов: возбуждающие, увеличивающие постсинаптическую деполяризацию и подводящие нейрон ближе к порогу генерации, и тормозящие, действующие в противоположном направлении.

В процессе работы клетка интегрирует небольшие изменения мембранного потенциала, обусловленные входами, однако этот процесс является нелинейным по отношению к временному интегралу эффективности передачи: потенциал проявляет тенденцию к внезапному выравниванию. Если эффективность передачи постоянна, то выравнивание потенциалов происходит приблизительно по экспоненциальному закону. Это явление называется временным суммированием. В действительности экспоненциальный закон не совсем точно отражает процесс выравнивания потенциала, который на самом деле происходит несколько быстрее.

Контрольные вопросы и задания

1. Перечислите основные компоненты нервной клетки.
2. Охарактеризуйте структуру пирамидальных клеток.
3. Как организуется взаимодействие между нейронами?
4. В чем заключаются особенности структуры клеток Пуркинье?
5. Как реализуется синаптическая связь между нейронами?
6. Поясните смысл принципа латерального торможения в нервных клетках.
7. Дайте определение и приведите примеры рецептивных полей.
8. Как организованы сигнальные связи между нейронами?
9. Охарактеризуйте закон, описывающий зависимость выходных импульсов от параметров процесса взаимодействия медиаторов и рецепторов на мембрану клетки.

Глава 2. МОДЕЛИРОВАНИЕ НЕЙРОННЫХ СЕТЕЙ

2.1. Структура и свойства искусственного нейрона

В настоящее время собрано очень мало информации о точных функциональных законах передачи сигналов в различных нервных клетках (за исключением мотонейрона – выходного нейрона в спинном мозге, передающего сигналы от мозга к мышцам). Несмотря на это в литературе обсуждается множества упрощенных моделей нейронов различной структуры, причем приводятся весьма далеко идущие выводы, касающиеся возможной организации и алгоритмов функционирования нейронов. Одна из наиболее распространенных моделей нервной клетки – так называемый *формальный нейрон* – была предложена Маккеломом и Питсом. В рамках этой модели нейрон рассматривается как триггерное устройство с пороговым уровнем. Если сумма входных сигналов превышает некоторый пороговый уровень, генерируется выходной сигнал определенной величины. В противном случае выходной сигнал равен нулю. Это означает, что формальный нейрон представляет собой логическую схему, которая может реализовывать произвольные булевы функции, зависящие от входных сигналов и величины порогового уровня.

В теории формальных нейронов принят ряд допущений, основными из которых являются следующие:

- активность нейрона следует рассматривать как процесс, включающий операции типа «все или ничего»;
- для возбуждения нейрона в некоторый момент времени на протяжении периода скрытого накопления должно быть возбуждено определенное число синапсов, причем это число не зависит от предшествующей активности и от положения нейрона в нервной сети;
- внутри нервной системы единственный механизм задержки сигналов обусловлен синаптической задержкой;
- активация любого тормозящего синапса полностью предотвращает возбуждение нейрона в данный момент времени;
- структура нейронной сети не изменяется с течением времени.

Наиболее серьезная критика этих допущений касается прежде всего принципа работы «все или ничего». Вообще следует отметить, что по крайней мере на высших уровнях нервной системы нейроны возбуждаются непрерывно, причем скорость возбуждения увеличивается за счет возбуждающих входов и уменьшается за счет тормозящих входов. Поэтому допущение о том, что тормозящий вход полностью блокирует активность нейрона, едва ли может быть принято. Другой общепринятый принцип заключается в том, что интенсивности сигналов (по крайней мере в периферийных нервах) кодируются частотой импульсов, т.е. имеют непрерывно изменяющийся масштаб значений. Можно предположить, что передаточная функция нейрона напоминает передаточную функцию импульсно-частотного модулятора.

На рис. 2.1 показана упрощенная электрическая модель нейрона, состоящая из пассивных электрических компонентов и активного триггерного устройства. Вход нейрона, моделирующий действие возбуждающих и тормозящих синапсов, представляется в виде генератора тока $I(t)$, передача импульса моделируется путем заряда конденсатора C , характеризующего емкость клеточной мембраны, шунтированной сопротивлением R . Если напряжение на конденсаторе превышает некоторое критическое – пороговый уровень триггера, – генерируется выходной импульс высокой энергии и одновременно емкость разряжается до уровня L . В реальных нейронах порог переключения после генерации зависит от времени, т.е. разряд не является идеальным. Эти уточнения, однако, не меняют существа дела, заключающегося в том, что в процессе непрерывной работы скорость следования выходных импульсов непрерывно зависит от эффективности передачи сигналов, если она достаточно велика.

В упрощенной электрической модели временного суммирования, приведенной на рис. 2.1, процессы заряда и разряда мембранной емкости C оказываются разделенными с процессом генерации выходных импульсов. Поэтому сигнал напряжения $U(t)$, связанный с емкостью, не совпадает с сигналом, записанным от реальной клетки; это обусловлено, главным образом, разнесением местоположений устройства переключения и самого нейрона.

Предположим, что эффективность передачи сигнала постоянна и равна I , кроме того, после разряда напряжение $U(t)$ начинает увеличиваться от уровня L в момент времени t_0 . Можно показать, что напряжение задается следующей функцией времени:

$$U(t) = RI + \left(\frac{L}{RC} - \frac{I}{C} \right) \exp(-(t-t_0)/RC), \quad (2.1)$$

а также, если обозначить момент времени, когда $U(t)$ достигает порога T через t_n , и положить $RC=1$

$$t_n - t_0 = \ln(I-L/R) - \ln(I-T/R). \quad (2.2)$$

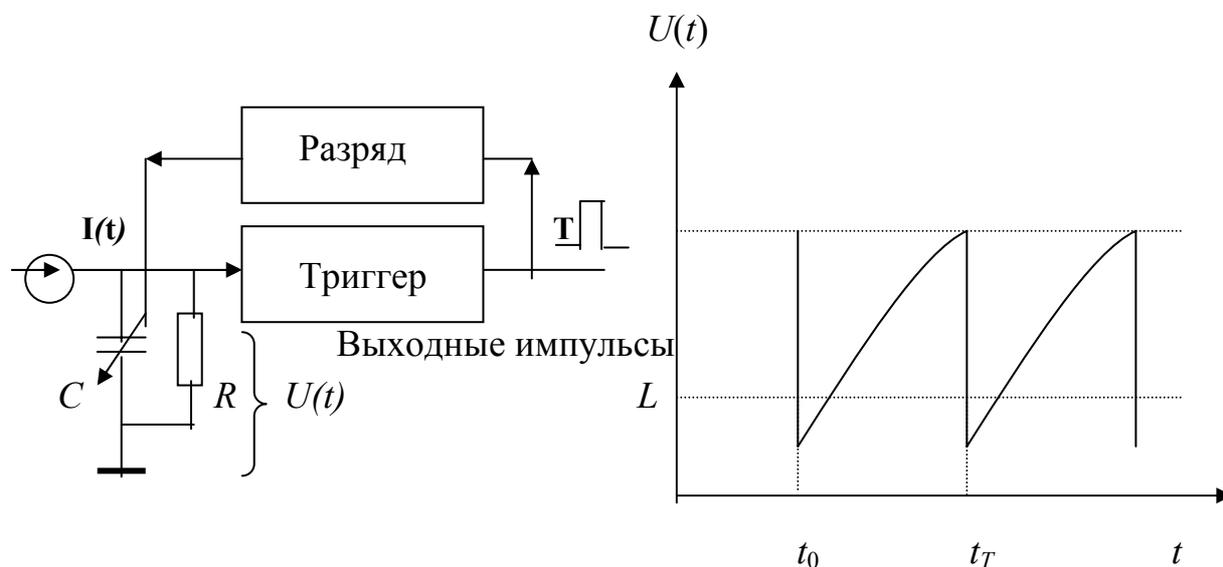


Рис. 2.1. Модель нейрона в виде импульсно-частотного модулятора

После разряда опять подается тот же самый сигнал напряжения. Тогда скорость переключения f равна

$$f = 1/(t_n - t_0). \quad (2.3)$$

Графическое представление функции $f(I)$ в относительных координатах показано на рис. 2.2. Как видно, до активизации системы существует «порог» эффективности передачи, не совпадающий с величиной T .

Заметим, однако, что если путем наложения фоновой постоянной эффективности передачи нормальное функционирование переключено на режим с более высоким значением порога, то работа элемента становится линейной и непрерывной: в этом случае изменения I приводят к прямо пропорциональным изменениям f . Приведенные выше рассуждения представляют собой так называемую *гипотезу линейности*.

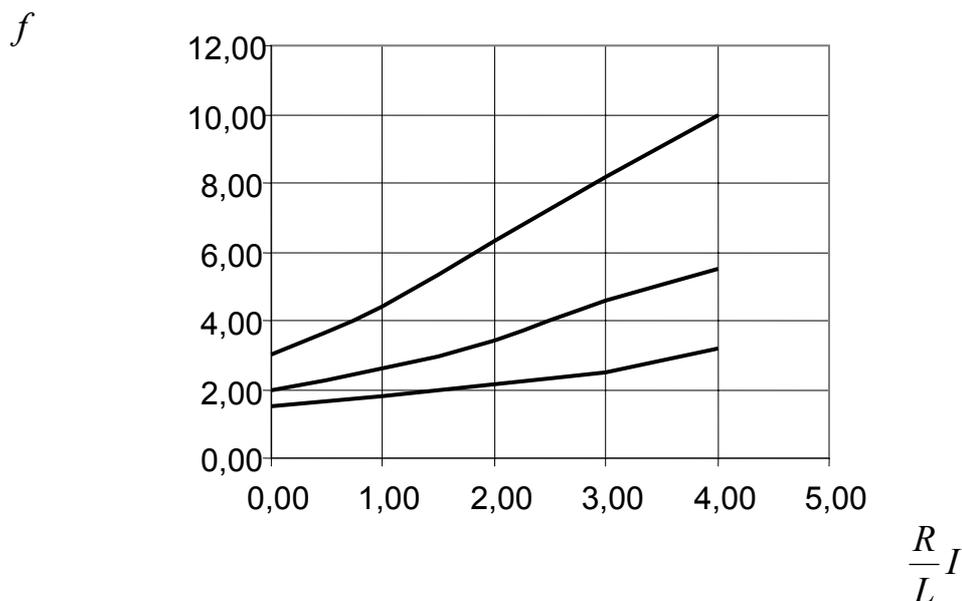


Рис. 2.2. Зависимость выходной частоты от входного тока для модели нейрона, показанной на рис. 2.1

Полную усредненную во времени эффективность передачи I для рассматриваемой упрощенной модели можно представить в виде взвешенной суммы частот импульсов отдельных входов, сходящихся на данный нейрон. Если выходную частоту обозначить через η , фоновую активность – через η_b и пресинаптические входные частоты через ξ_i , $i=1, 2, \dots, n$, то линеаризованную передаточную функцию можно записать в следующем виде:

$$\eta = \eta_b + \sum_{i=1}^n \mu_i \xi_i, \quad (2.4)$$

где μ_i характеризует эффективности синапсов. На рис. 2.3 показана математическая модель нейрона.

Искусственный нейрон состоит из элементов трех типов: умножителей (синапсов), сумматора и нелинейного преобразователя. Синапсы осуществляют связь между нейронами, умножают входной сигнал на число, характеризующее силу связи (вес синапса).

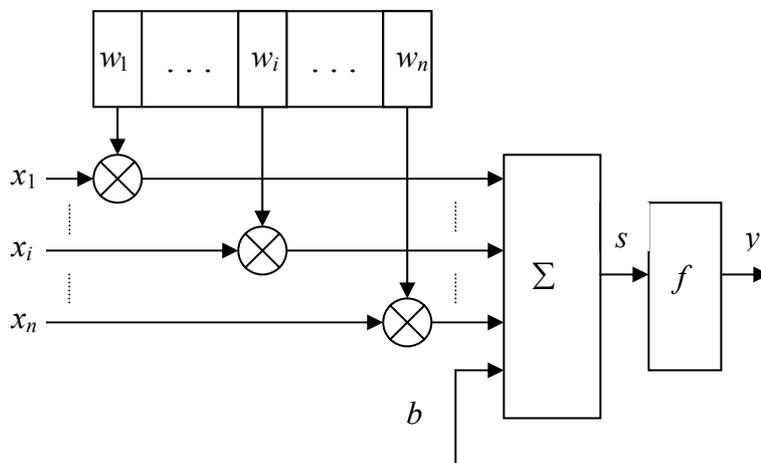


Рис. 2.3. Математическая модель нейрона

Сумматор выполняет сложение сигналов, поступающих по синаптическим связям от других нейронов, и внешних входных сигналов. Нелинейный преобразователь реализует нелинейную функцию одного аргумента – выхода сумматора. Эта функция называется *функцией активации*, или *передаточной функцией*, нейрона. Нейрон в целом реализует скалярную функцию векторного аргумента

$$s = \sum_{i=1}^n w_i x_i + b, \quad (2.5)$$

$$y = f(s), \quad (2.6)$$

где w_i – вес синапса, $i = 1 \dots n$; b – значение смещения; s – результат суммирования; x_i – компонент входного вектора (входной сигнал), $i = 1 \dots n$; y – выходной сигнал нейрона; n – число входов нейрона; f – нелинейное преобразование (функция активации).

В общем случае входной сигнал, весовые коэффициенты и смещение могут принимать действительные значения, а во многих практических задачах – лишь некоторые фиксированные значения. Выход y определяется видом функции активации и может быть как действительным, так и целым. Синаптические связи с положительными весами называют *возбуждающими*, с отрицательными весами – *тормозящими*.

Описанный вычислительный элемент можно считать упрощенной математической моделью биологических нейронов. Чтобы подчеркнуть различие нейронов биологических и искусственных, вторые иногда называют *нейроподобными элементами*, или *формальными нейронами*.

На входной сигнал s нелинейный преобразователь отвечает выходным сигналом $f(s)$, который представляет собой выход у нейрона. Примеры активационных функций представлены в табл. 2.1 и на рис. 2.4.

Таблица 2.1

Функции активации нейронов

Функция	Формула	Область значений
Линейная	$f(s) = ks$	$(-\infty, \infty)$
Полулинейная	$f(s) = \begin{cases} ks, & s > 0 \\ 0, & s \leq 0 \end{cases}$	$(0, \infty)$
Логистическая (сигмоидальная)	$f(s) = \frac{1}{1 + e^{-as}}$	$(0, 1)$
Гиперболический тангенс (сигмоидальная)	$f(s) = \frac{e^{as} - e^{-as}}{e^{as} + e^{-as}}$	$(-1, 1)$
Экспоненциальная	$f(s) = e^{-as}$	$(0, \infty)$
Синусоидальная	$f(s) = \sin(s)$	$(-1, 1)$
Сигмоидальная (рациональная)	$f(s) = \frac{s}{a + s }$	$(-1, 1)$
Шаговая (линейная с насыщением)	$f(s) = \begin{cases} -1, & s \leq -1, \\ s, & -1 < s < 1, \\ 1, & s \geq 1 \end{cases}$	$(-1, 1)$
Пороговая	$f(s) = \begin{cases} 0, & s < 0, \\ 1, & s \geq 0 \end{cases}$	$(0, 1)$
Модульная	$f(s) = s $	$(0, \infty)$
Знаковая (сигнатурная)	$f(s) = \begin{cases} 1, & s > 0, \\ -1, & s \leq 0 \end{cases}$	$(-1, 1)$
Квадратичная	$f(s) = s^2$	$(0, \infty)$

Одной из наиболее распространенных является нелинейная функция активации с насыщением, так называемая логистическая функция, или сигмоид (функция s -образного вида):

$$f(s) = \frac{1}{1 + e^{-as}}. \quad (2.7)$$

При уменьшении параметра a сигмоид становится более пологим, в пределе при $a = 0$ вырождаясь в горизонтальную линию на уровне 0,5, при увеличении a сигмоид приближается к виду функции единичного скачка с порогом Θ .

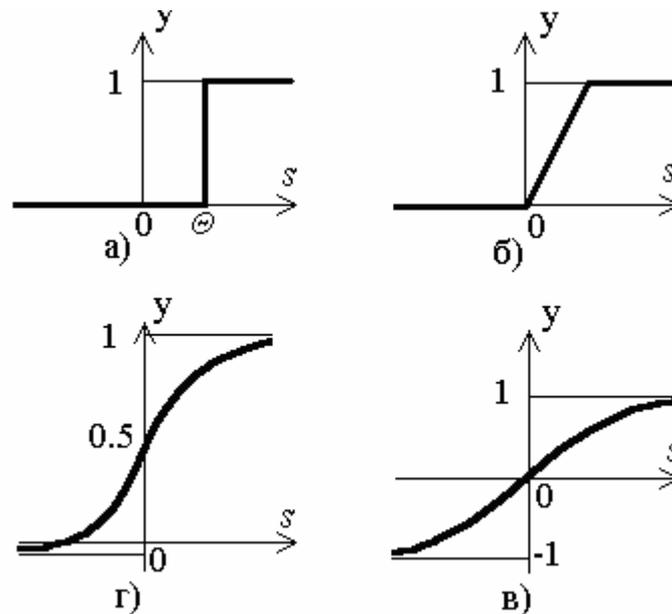


Рис. 2.4. Примеры активационных функций: а – функция единичного скачка; б – линейный порог (гистерезис); в – сигмоид (гиперболический тангенс); г – сигмоид (логистическая функция)

Из выражения для сигмоида очевидно, что выходное значение нейрона лежит в диапазоне (0, 1). Одним из ценных свойств сигмоидальной функции является простое выражение для ее производной:

$$f'(s) = a f(s) [1 - f(s)]. \quad (2.8)$$

Следует отметить, что сигмоидальная функция дифференцируема на всей оси абсцисс, что используется в некоторых алгоритмах обучения. Кроме того, она обладает свойством усиливать слабые сигналы лучше, чем большие, и предотвращает насыщение от больших сигналов, так как они соответствуют областям аргументов, где сигмоид имеет пологий наклон.

2.2. Классификация искусственных нейронных сетей

Нейронная сеть представляет собой совокупность нейроподобных элементов, определенным образом соединенных друг с другом и с внешней средой с помощью связей, определяемых весовыми коэффициентами. В зависимости от функций, выполняемых нейронами в сети, можно выделить три их типа:

- *входные нейроны*, на которые подается вектор, кодирующий входное воздействие или образ внешней среды; в них обычно не осуществляется вычислительных процедур, а информация передается с входа на выход путем изменения их активации;
- *выходные нейроны*, выходные значения которых представляют выходы нейронной сети; преобразования в них осуществляются по выражениям (2.5) и (2.6);
- *промежуточные нейроны*, составляющие основу нейронных сетей, преобразования в которых выполняются так же по выражениям (2.5) и (2.6).

В большинстве нейронных моделей тип нейрона связан с его расположением в сети. Если нейрон имеет только выходные связи, то это входной нейрон, выходной нейрон имеет только входные связи. Однако возможен случай, когда выход типологически внутреннего нейрона рассматривается как часть выхода сети. В процессе функционирования сети осуществляются преобразование входного вектора в выходной, некоторая переработка информации. Конкретный вид выполняемого сетью преобразования данных обуславливается не только характеристиками нейроподобных элементов, но и особенностями ее архитектуры, а именно топологией межнейронных связей, выбором определенных подмножеств нейроподобных элементов для ввода и вывода информации, способами обучения сети, наличием или отсутствием конкуренции между нейронами, направлением и способами управления и синхронизации передачи информации между нейронами.

С точки зрения топологии можно выделить три основных типа нейронных сетей (рис. 2.5):

- полносвязные (рис. 2.5,а);
- многослойные, или слоистые (рис. 2.5,б);
- слабосвязные (с локальными связями) (рис. 2.5,в).

В *полносвязных нейронных сетях* каждый нейрон передает свой выходной сигнал остальным нейронам, в том числе и самому себе. Все входные сигналы передаются всем нейронам. Выходными сигналами сети могут быть все или некоторые выходные сигналы нейронов после нескольких тактов функционирования сети.

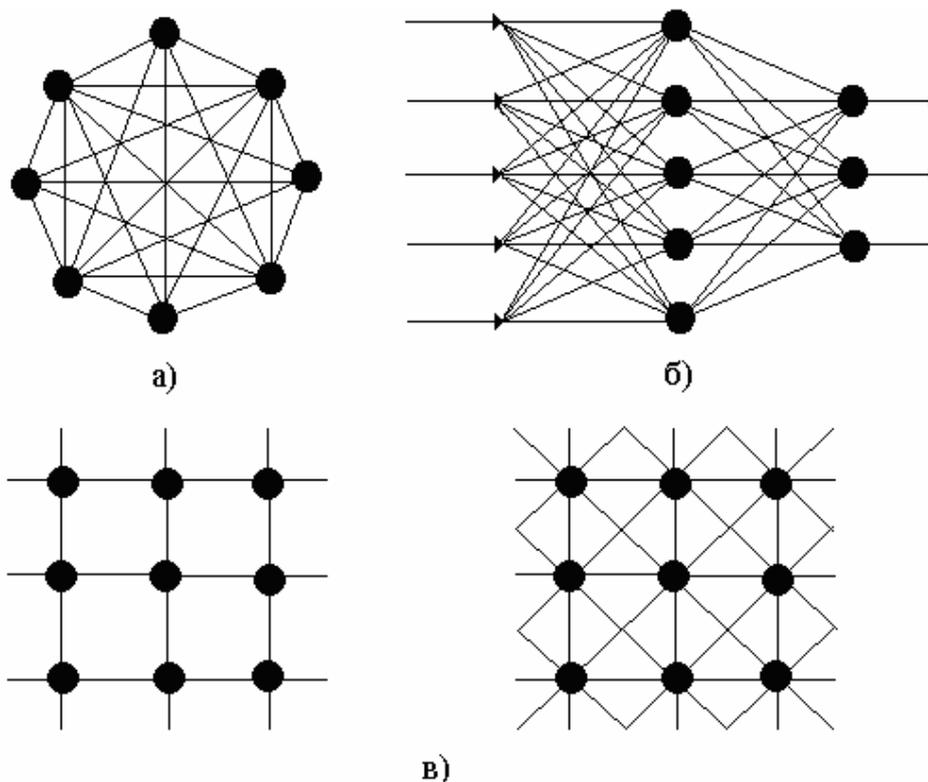


Рис. 2.5. Архитектура нейронных сетей: а – полносвязная сеть;
 б – многослойная сеть с последовательными связями;
 в – слабосвязные сети

В *многослойных нейронных сетях* нейроны объединяются в слои. Слой содержит совокупность нейронов с едиными входными сигналами. Число нейронов в слое может быть любым и не зависит от количества нейронов в других слоях. В общем случае сеть состоит из Q слоев, пронумерованных слева направо. Внешние входные сигналы подаются на входы нейронов входного слоя (его часто нумеруют как нулевой), а выходами сети являются выходные сигналы последнего слоя. Кроме входного и выходного слоев в многослойной нейронной сети есть один или несколько скрытых слоев. Связи от выходов нейронов некоторого слоя q к входам нейронов следующего слоя $(q+1)$ называют последовательными.

В свою очередь, среди многослойных нейронных сетей выделяют следующие типы:

1. *Монотонные.* Это частный случай слоистых сетей с дополнительными условиями на связи и нейроны. Каждый слой кроме последнего (выходного) разбит на два блока: возбуждающий и тормозящий. Связи между блоками тоже разделяются на тормозящие и возбуждающие. Если от нейронов блока А к нейронам блока В ведут только возбуждающие связи, то это означает, что любой выходной сигнал блока является монотонной неубывающей функцией любого выходного сигнала блока А. Если же эти связи только тормозящие, то любой выходной сигнал блока В является невозрастающей функцией любого выходного сигнала блока А. Для нейронов монотонных сетей необходима монотонная функция выходного сигнала нейрона от параметров выходных сигналов.

2. *Сети без обратных связей.* В таких сетях нейроны входного слоя получают входные сигналы, преобразуют их и передают нейронам первого скрытого слоя и так далее вплоть до выходного, который выдает сигналы для интерпретатора и пользователя. Если не оговорено противное, то каждый выходной сигнал q -го слоя подается на вход всех нейронов $(q+1)$ -го слоя; однако возможен вариант соединения q -го слоя с произвольным $(q+p)$ -м слоем.

Среди многослойных сетей без обратных связей различают полносвязанные (выход каждого нейрона q -го слоя связан с входом каждого нейрона $(q+1)$ -го слоя) и частично полносвязанные. Классическим вариантом слоистых сетей являются полносвязанные сети прямого распространения (рис. 2.6).

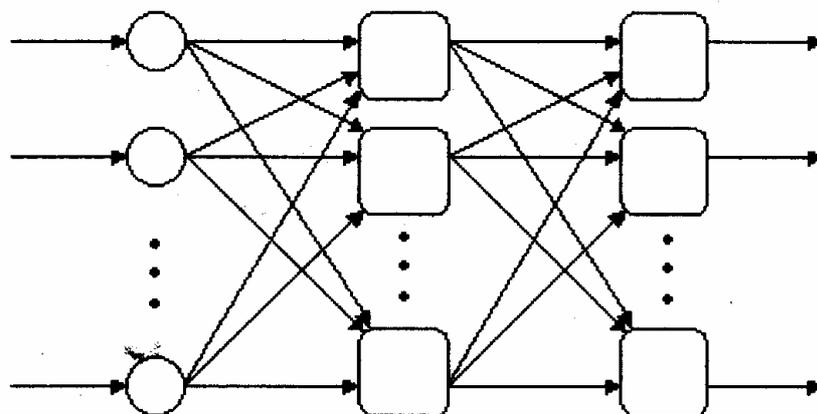


Рис. 2.6. Многослойная (двухслойная) сеть прямого распространения

3. *Сети с обратными связями.* В сетях с обратными связями информация с последующих слоев передается на предыдущие. Среди них, в свою очередь, выделяют следующие:

- слоисто-циклические, отличающиеся тем, что слои замкнуты в кольцо: последний слой передает свои выходные сигналы первому; все слои равноправны и могут как получать входные сигналы, так и выдавать выходные;

- слоисто-полносвязанные состоят из слоев, каждый из которых представляет собой полносвязанную сеть, а сигналы передаются как от слоя к слою, так и внутри слоя; в каждом слое цикл работы распадается на три части: прием сигналов с предыдущего слоя, обмен сигналами внутри слоя, выработка выходного сигнала и передача к последующему слою;

- полносвязанно-слоистые, по своей структуре аналогичные слоисто-полносвязанным, но функционирующие по-другому: в них не разделяются фазы обмена внутри слоя и передачи следующему, на каждом такте нейроны всех слоев принимают сигналы от нейронов как своего слоя, так и от последующих.

В качестве примера сетей с обратными связями на рис. 2.7 представлены частично-рекуррентные сети Элмана и Жордана.

В *слабосвязанных нейронных* сетях нейроны располагаются в узлах прямоугольной или гексагональной решетки. Каждый нейрон связан с четырьмя (окрестность фон Неймана), шестью (окрестность Голея) или восемью (окрестность Мура) своими ближайшими соседями.

Известные нейронные сети можно разделить по типам структур нейронов на гомогенные (однородные) и гетерогенные. Гомогенные сети состоят из нейронов одного типа с единой функцией активации, а в гетерогенную сеть входят нейроны с различными функциями активации.

Существуют бинарные и аналоговые сети. Бинарные сети оперируют только двоичными сигналами, и выход каждого нейрона может принимать значение либо логического нуля (заторможенное состояние), либо логической единицы (возбужденное состояние).

Нейронные сети можно разделить на синхронные и асинхронные. В первом случае в каждый момент времени лишь один нейрон меняет свое состояние, во втором – состояние меняется сразу у целой группы нейро-

нов, как правило, у всего слоя. Алгоритмически ход времени в нейронных сетях задается итерационным выполнением однотипных действий над нейронами.

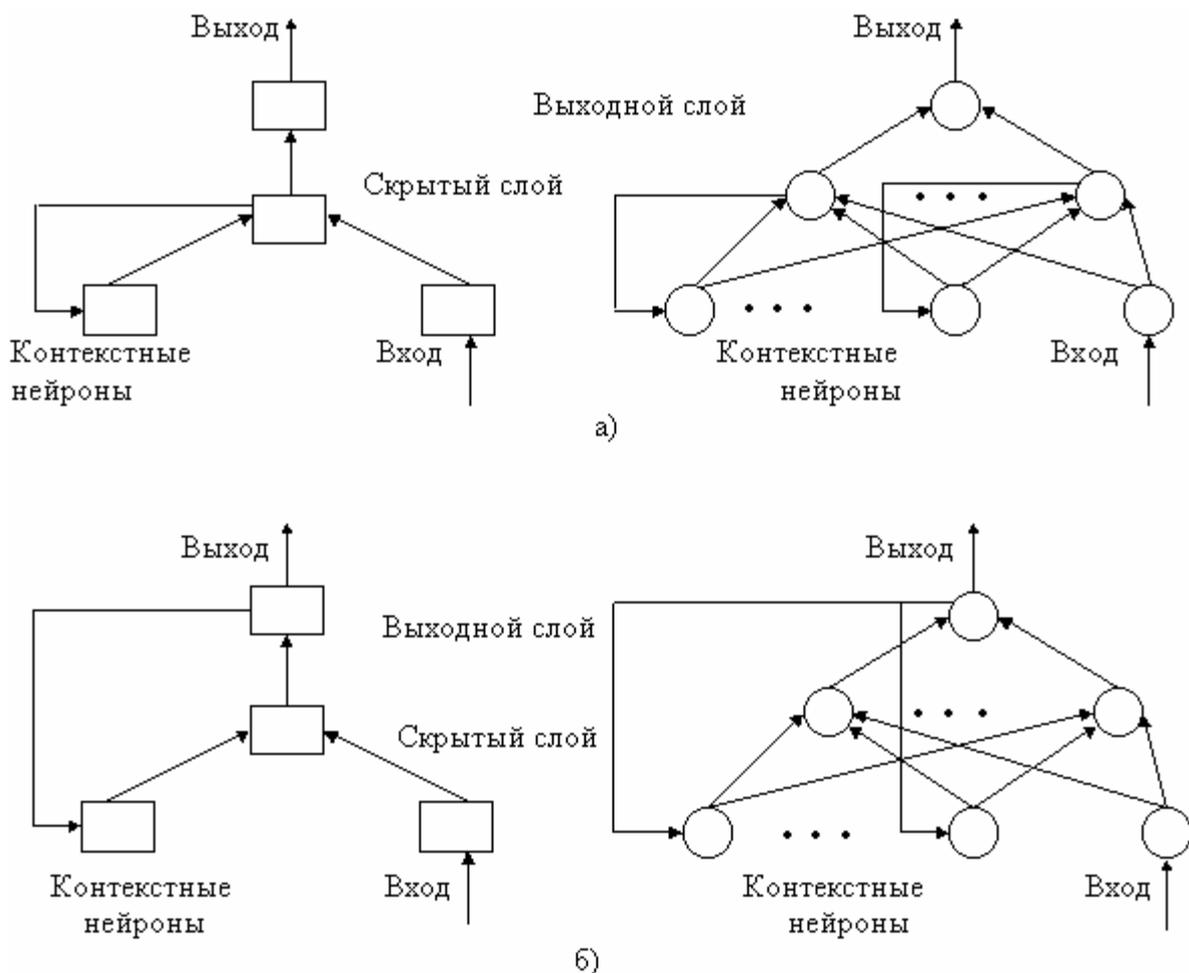


Рис. 2.7. Частично-рекуррентные сети: а – Элмана; б – Жордана

Сети можно классифицировать также по числу слоев. Теоретически число слоев и число нейронов в каждом слое могут быть произвольными, однако фактически оно ограничено ресурсами компьютера или специализированных микросхем, на которых обычно реализуется нейронная сеть. Чем сложнее сеть, тем более сложные задачи она может решать.

Выбор структуры нейронной сети осуществляется в соответствии с особенностями и сложностью задачи. Для решения отдельных типов задач уже существуют оптимальные конфигурации нейронных сетей. Если же задача не может быть сведена ни к одному из известных типов, приходится решать сложную проблему синтеза новой конфигурации. При этом

необходимо руководствоваться следующими основными правилами:

- возможности сети возрастают с увеличением числа нейронов сети, плотности связей между ними и числом слоев;
- введение обратных связей наряду с увеличением возможностей сети требует решения задачи динамической устойчивости сети;
- сложность алгоритмов функционирования сети, введение нескольких типов синапсов способствуют усилению мощности нейронной сети.

Вопрос о необходимых и достаточных свойствах сети для решения задач того или иного рода представляет собой целое направление нейрокомпьютерной науки. Так как проблема синтеза нейронной сети существенно зависит от решаемой задачи, дать общие подробные рекомендации затруднительно. В большинстве случаев оптимальный вариант получается на основе интуитивного подбора, хотя в литературе приведены доказательства того, что для любого алгоритма существует нейронная сеть, которая может его реализовать.

Многие задачи распознавания образов (зрительных, речевых), выполнения функциональных преобразований при обработке сигналов, управления, прогнозирования, идентификации сложных систем сводятся к следующей математической постановке. Необходимо построить такое отображение $X \rightarrow Y$, чтобы на каждый возможный входной сигнал X формировался правильный выходной сигнал Y . Отображение задается конечным набором пар ($\langle \text{вход} \rangle$, $\langle \text{известный выход} \rangle$). Число этих пар (обучающих примеров) существенно меньше общего числа возможных сочетаний значений входных и выходных сигналов. Совокупность всех обучающих примеров носит название обучающей выработки.

В задачах распознавания образов X – некоторое представление образа (изображение, вектор), Y – номер класса, к которому принадлежит входной образ.

В задачах управления X – набор контролируемых параметров управляемого объекта, Y – код, определяющий управляющее воздействие, соответствующее текущим значениям контролируемых параметров.

В задачах прогнозирования в качестве входных сигналов используются временные ряды, представляющие значения контролируемых переменных на некотором интервале времени. Выходной сигнал – множество переменных, которое является подмножеством переменных входного сигнала.

При идентификации X и Y представляют входные и выходные сигналы системы соответственно.

Вообще говоря, значительная часть прикладных задач может быть сведена к реализации некоторого сложного функционального многомерного преобразования.

В результате отображения $X \rightarrow Y$ необходимо обеспечить формирование правильных выходных сигналов в соответствии:

- со всеми примерами обучающей выборки;
- всеми возможными входными сигналами, которые не вошли в обучающую выборку.

Второе требование в значительной степени усложняет задачу формирования обучающей выборки. В общем виде эта задача в настоящее время еще не решена, однако во всех известных случаях может быть найдено частное решение.

2.3. Алгоритмы обучения нейронных сетей

Постановка задачи обучения

Процесс функционирования нейронной сети, задачи, которые она способна решать, зависят от величин синаптических связей. Поэтому при заданной структуре сети необходимо найти оптимальные значения всех переменных весовых коэффициентов (некоторые синаптические связи могут быть постоянными).

Этот этап называется обучением нейронной сети, и от того, насколько качественно он будет выполнен, зависит способность сети решать поставленные перед ней проблемы.

В процессе функционирования нейронная сеть формирует выходной сигнал Y в соответствии с входным сигналом X , реализуя некоторую функцию $g: Y=g(X)$. Если архитектура сети задана, то вид функции g определяется значениями синаптических весов и смещенной сети. Обозначим через G множество всех возможных функций g , соответствующих заданной архитектуре сети.

Пусть решением некоторой задачи является функция $r: Y=r(X)$, заданная парами $(X^1, Y^1), \dots, (X^k, Y^k)$, для которых $Y^k=r(X^k)$, $k = 1 \dots N$. E – функция ошибки (функционал качества), показывающая для каждой из функций g степень близости к r .

Решить поставленную задачу с помощью нейронной сети заданной архитектуры – это значит построить (синтезировать) функцию $g \in G$, подобрав параметры нейронов (синаптические веса и смещения) таким образом, чтобы функционал качества обращался в оптимум для всех пар (X^k, Y^k) .

Таким образом, задача обучения нейронной сети определяется совокупностью пяти компонентов:

$$\langle X, Y, r, G, E \rangle. \quad (2.9)$$

Обучение состоит в поиске (синтезе) функции g , оптимальной по E (рис. 2.8). Процесс обучения сети требует длительных вычислений и представляет собой итерационную процедуру. Число итераций может составлять от 10^3 до 10^8 . На каждой итерации происходит уменьшение функции ошибки.

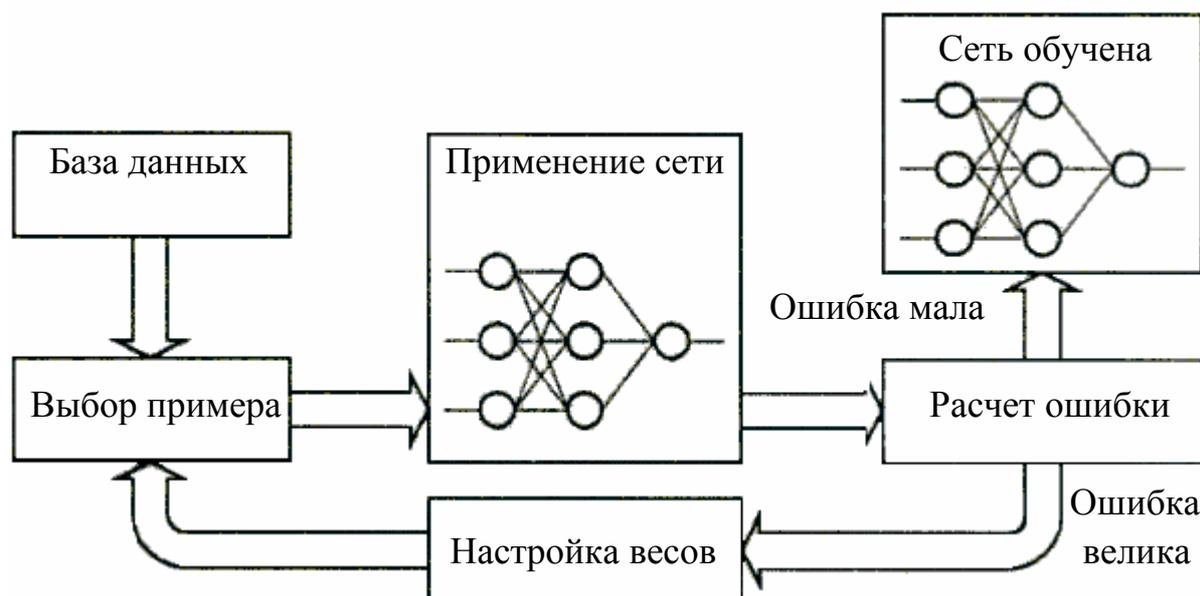


Рис. 2.8. Процесс обучения нейронной сети

Функция E может иметь произвольный вид. Если выбраны множество обучающих примеров и способ вычисления функции ошибки, обучение нейронной сети может быть представлено в виде задачи многомерной оптимизации, для решения которой используются следующие методы:

- локальной оптимизации с вычислением частных производных первого порядка;
- локальной оптимизации с вычислением частных производных первого и второго порядков;

- стохастической оптимизации;
- глобальной оптимизации.

К первой группе относятся градиентный метод (наискорейшего спуска); методы с одномерной и двумерной оптимизацией целевой функции в направлении антиградиента; метод сопряженных градиентов; методы, учитывающие направление антиградиента на нескольких шагах алгоритма.

Ко второй группе относятся метод Ньютона, методы оптимизации с разреженными матрицами Гессе, квазиньютоновские методы, метод Гаусса – Ньютона, метод Левенберга – Маркардта.

Стохастическими методами являются поиск в случайном направлении, имитация отжига, метод Монте-Карло (численный метод статистических испытаний).

Задачи глобальной оптимизации решаются с помощью перебора значений переменных, от которых зависит целевая функция.

Для сравнения методов обучения нейронных сетей необходимо использовать два критерия:

- количество шагов алгоритма для получения решения;
- количество дополнительных переменных для организации вычислительного процесса.

Предпочтение следует отдавать тем методам, которые позволяют обучить нейронную сеть за небольшое число шагов и требуют малого числа дополнительных переменных. Это связано с ограничением ресурсов вычислительных средств.

Пусть нейронная сеть содержит P изменяемых параметров (синаптических весов и смещений). Существуют лишь две группы алгоритмов обучения, которые требуют менее $2P$ дополнительных параметров и при этом дают возможность обучать нейронные сети за приемлемое число шагов. Это алгоритмы с вычислением частных производных первого порядка и, возможно, одномерной оптимизации.

Указанные алгоритмы дают возможность находить только локальные экстремумы, но они могут быть использованы на практике для обучения нейронных сетей с многоэкстремальными целевыми функциями (функциями ошибки), так как экстремумов у целевой функции, как правило, не очень много. Достаточно лишь несколько раз вывести сеть из локального минимума с большим значением целевой функции для того, чтобы в ре-

зультате итераций в соответствии с алгоритмом локальной оптимизации сеть оказалась в локальном минимуме со значением целевой функции, близким к нулю. Если после нескольких попыток вывести сеть из локального минимума нужного эффекта добиться не удастся, необходимо увеличить число нейронов во всех слоях с первого до предпоследнего и присвоить случайным образом их синаптическим весам и смещениям значения из заданного диапазона.

Эксперименты по обучению нейронных сетей показали, что совместное использование алгоритма локальной оптимизации, процедуры вывода сети из локального минимума и процедуры увеличения числа нейронов приводят к успешному обучению нейронных сетей.

Стохастические алгоритмы требуют очень большого числа шагов обучения. Это делает невозможным их практическое использование для обучения нейронных сетей больших размерностей. Экспоненциальный рост сложности перебора с ростом размерности задачи в алгоритмах глобальной оптимизации при отсутствии априорной информации о характере целевой функции также делает невозможным их использование для обучения нейронных сетей больших размерностей. Метод сопряженных градиентов очень чувствителен к точности вычислений, особенно при решении задач оптимизации большой размерности. Для методов, учитывающих направление антиградиента на нескольких шагах алгоритма, и методов, включающих вычисление матрицы Гессе, необходимо более чем $2P$ дополнительных переменных. В зависимости от способа разрежения вычисление матрицы Гессе требует от $2P$ до P^2 дополнительных переменных.

Алгоритм обучения персептрона

Искусственная нейронная сеть, представленная на рис. 2.9,а называется персептроном. Эта сеть (и множество ей подобных) состоит из одного слоя искусственных нейронов (см. рис. 2.9,б), соединенных с помощью весовых коэффициентов выходами y_i . Элемент Σ персептронного нейрона умножает каждый вход x_i на вес w_{ij} и суммирует взвешенные входы. Если эта сумма больше заданного порогового значения, выход равен единице, в противном случае – нулю.

Несмотря на ограничения, персептроны широко изучались. Теория персептронов является основой для изучения многих других типов искус-

ственных нейронных сетей. Рассмотрим в качестве примера функционирование трехнейронного персептрона.

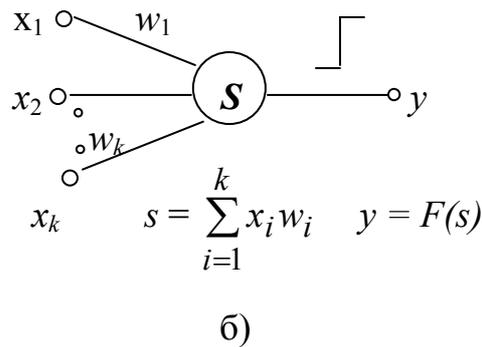
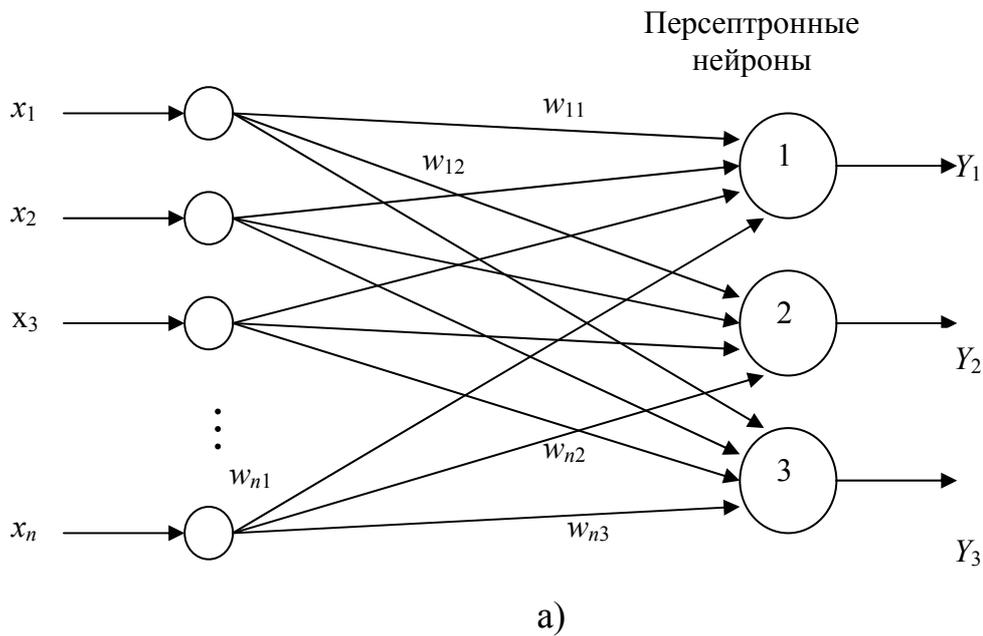


Рис. 2.9. Однослойный персептрон: а – модуль персептрона; б – однослойная нейронная сеть

На n входов подаются сигналы x_i , поступающие далее по синапсам на три нейрона, которые образуют единственный слой этой сети. На выходах сети формируются сигналы:

$$y_j = f\left(\sum_{i=1}^n x_i w_{ij}\right), j = 1 \dots 3. \quad (2.10)$$

Весовые коэффициенты синапсов одного слоя нейронов можно свести в матрицу W , в которой каждый элемент w_{ij} задает величину i -й синапти-

ческой связи j -го нейрона. Таким образом, процесс, происходящий в нейронной сети, может быть записан в матричной форме:

$$Y = F(XW), \quad (2.11)$$

где X и Y – соответственно входной и выходной векторы (под вектором понимается вектор-строка); $F(S)$ – активационная функция, применяемая поэлементно к компонентам вектора S .

На рис. 2.10 представлен двухслойный персептрон, образованный из однослойного добавлением второго слоя, состоящего из двух нейронов.

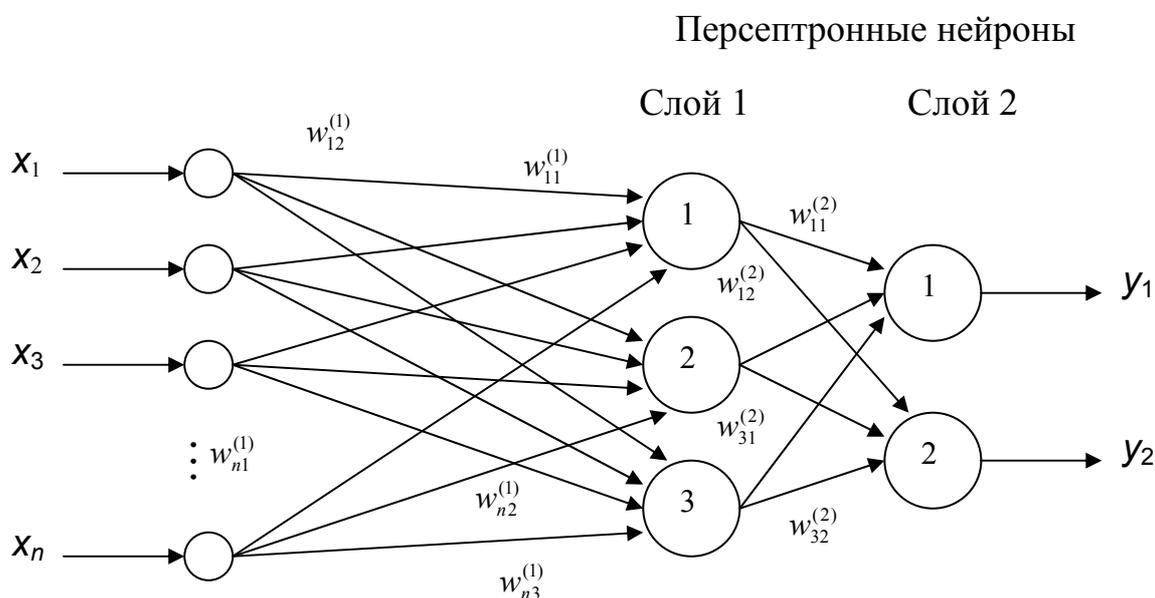


Рис. 2.10. Двухслойный персептрон: 1, 2, 3 – номера нейронов

Следует отметить важную роль нелинейности активационной функции, так как, если бы она не обладала данным свойством, результат функционирования любой Q -слойной нейронной сети с весовыми матрицами $W^{(q)}$ для каждого слоя $q = 1 \dots Q$ свелся бы к перемножению входного вектора сигналов X на матрицу:

$$W^{(\Sigma)} = W^{(1)} \dots W^{(q)} \dots W^{(Q)}. \quad (2.12)$$

Фактически такая Q -слойная нейронная сеть эквивалентна сети с од-

ним скрытым слоем и с весовой матрицей единственного слоя $W^{(\Sigma)}$:

$$Y = X W^{(\Sigma)}. \quad (2.13)$$

Работа персептрона сводится к классификации (обобщению) входных сигналов, принадлежащих n -мерному гиперпространству, по некоторому числу классов. С математической точки зрения это происходит путем разбиения гиперпространства гиперплоскостями. Для однослойного персептрона

$$\sum_{i=1}^n x_i w_{ir} = \theta_r, \quad r = 1 \dots m. \quad (2.14)$$

Каждая полученная область является областью определения отдельного класса. Число таких классов для персептрона не превышает 2^m , где m – число его выходов. Однако не все классы могут быть разделимы данной нейронной сетью.

Например, однослойный персептрон, состоящий из одного нейрона с двумя входами, не может реализовать логическую функцию “Исключающее ИЛИ”, т.е. не способен разделить плоскость (двумерное гиперпространство) на две полуплоскости так, чтобы осуществить классификацию входных сигналов по классам A и B (табл. 2.2).

Таблица 2.2

Логическая функция “Исключающее ИЛИ”

x_1	x_2	
	0	1
0	B	A
1	A	B

Уравнение сети для этого случая является уравнением прямой

$$x_1 w_1 + x_2 w_2 = \theta, \quad (2.15)$$

которая ни при каких условиях не может разделить плоскость так, чтобы точки из множества входных сигналов, принадлежащие разным классам, оказались по разные стороны от прямой (рис. 2.11). Невозможность реали-

зации однослойным персептроном этой функции получила название проблемы «Исключающего ИЛИ».

Отметим, что функции, которые не реализуются однослойным персептроном, называются линейно неразделимыми. Решение задач, попадающих под это ограничение, заключается в применении двух- и более слойных сетей или сетей с нелинейными синапсами, однако и тогда существует вероятность, что корректное разделение некоторых входных сигналов на классы невозможно.

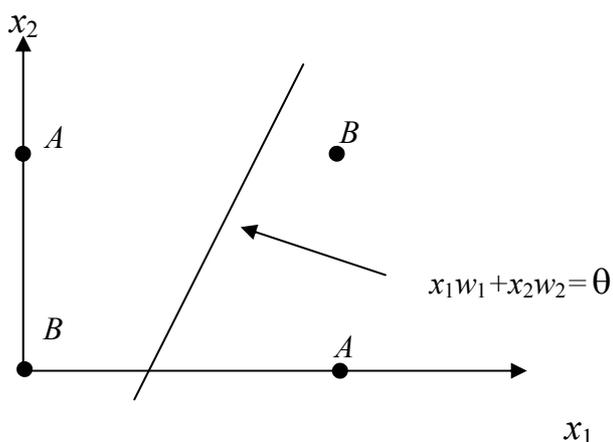


Рис. 2.11. Линейная неразделимость функции «Исключающее ИЛИ»

Рассмотрим алгоритм обучения с учителем однослойного персептрона, представленного на рис. 2.9.

ШАГ 1. Проинициализировать элементы весовой матрицы небольшими случайными значениями.

ШАГ 2. Подать на входы один из входных векторов, которые сеть должна научиться распознавать, и вычислить ее выход.

ШАГ 3. Если выход правильный, перейти на шаг 4, если неправильный – вычислить разницу между требуемым и полученным значениями выхода:

$$\delta = d - Y. \quad (2.16)$$

Модифицировать веса в соответствии с формулой

$$w_{ij}(t+1) = w_{ij}(t) + \eta \delta(x_j), \quad (2.17)$$

где t и $t+1$ – номера текущей и следующей итераций; η – коэффициент

скорости обучения, $0 < \eta < 1$; i – номер входа; j – номер нейрона в слое. Из соотношений (2.15), (2.16) следует, что если $d < Y$, то весовые коэффициенты будут увеличены и тем самым уменьшат ошибку. В противном случае они будут уменьшены, и Y тоже уменьшится, приближаясь к d . Обучение продолжается до тех пор, пока сеть не перестанет ошибаться.

На шаге 2 на разных итерациях поочередно в случайном порядке предъявляются все возможные входные векторы. К сожалению, нельзя заранее определить число итераций, которые потребуется выполнить, а в некоторых случаях и гарантировать полный успех.

Сходимость процедуры обучения рассмотренной сети устанавливается следующими теоремами.

Теорема 2.1

Класс элементарных перцептронов, для которых существует решение для любой заданной классификации, не является пустым.

Эта теорема утверждает, что для любой классификации обучающей выборки можно подобрать такой набор (из бесконечного набора) элементарных нейронов, в котором будет осуществлено разделение обучающей последовательности при помощи линейного решающего правила.

Теорема 2.2

Если для некоторой классификации решение существует, то в процессе обучения перцептрона с коррекцией ошибок, начинающегося с произвольного исходного состояния, это решение будет достигнуто в течение конечного промежутка времени.

Смысл теоремы состоит в том, что если относительно заданной классификации можно найти набор элементов, в котором существует решение, то в рамках этого набора оно будет достигнуто за конечный промежуток времени.

Алгоритм обратного распространения ошибки

В многослойных нейронных сетях оптимальные выходные значения нейронов всех слоев, кроме последнего, как правило, неизвестны. Трех- или более слойный перцептрон уже невозможно обучить, руководствуясь только величинами ошибок на выходах сети.

Один из вариантов решения этой проблемы – разработка наборов выходных сигналов, соответствующих входным, для каждого слоя нейронной сети, что, конечно, является очень трудоемкой операцией и не всегда осуществимо. Вторым вариантом – динамическая подстройка весовых коэффициентов синапсов, в ходе которой выбираются, как правило, наиболее слабые связи и изменяются на малую величину в ту или иную сторону, а сохраняются только те изменения, которые повлекли уменьшение ошибки на выходе всей сети. Очевидно, что данный метод, несмотря на кажущуюся простоту, требует громоздких рутинных вычислений. И, наконец, третий, более приемлемый вариант – распространение сигналов ошибки от выходов нейронной сети к ее входам в направлении, обратном прямому распространению сигналов в обычном режиме работы. Этот алгоритм обучения получил название процедуры *обратного распространения ошибки* (error back propagation).

Алгоритм обратного распространения ошибки представляет собой итеративный градиентный алгоритм обучения, который используется с целью минимизации среднеквадратичного отклонения текущих от требуемых выходов многослойных нейронных сетей с последовательными связями.

Согласно методу наименьших квадратов минимизируемой целевой функцией ошибки нейронной сети является величина

$$E(w) = \frac{1}{2} \sum_{j,k} (y_{j,k}^{(Q)} - d_{j,k})^2, \quad (2.18)$$

где $y_{j,k}^{(Q)}$ – реальное выходное состояние нейрона j -го выходного слоя нейронной сети при подаче на ее входы k -го образа; $d_{j,k}$ – требуемое выходное состояние этого нейрона.

Суммирование ведется по всем нейронам выходного слоя и по всем обрабатываемым сетью образам. Минимизация методом градиентного спуска обеспечивает подстройку весовых коэффициентов следующим образом:

$$\Delta w_{ij}^{(q)} = -\eta \frac{\partial E}{\partial w_{ij}}, \quad (2.19)$$

где w_{ij} – весовой коэффициент синаптической связи, соединяющей i -й нейрон слоя $(q-1)$ с j -м нейроном слоя q ; η – коэффициент скорости обуче-

ния. В соответствии с правилом дифференцирования сложной функции

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \frac{dy_j}{ds_j} \frac{\partial s_j}{\partial w_{ij}}, \quad (2.20)$$

где s_j – взвешенная сумма входных сигналов нейрона j , т.е. аргумент активационной функции. Так как производная активационной функции должна быть определена на всей оси абсцисс, то функция единичного скачка и прочие активационные функции с неоднородностями не подходят для рассматриваемых нейронных сетей. В них применяются такие гладкие функции, как гиперболический тангенс или классический сигмоид с экспонентой. Например, в случае гиперболического тангенса

$$\frac{dy}{ds} = 1 - s^2.$$

Третий множитель выражения (2.20) $\partial s_j / \partial w_{ij}$ равен выходу нейрона предыдущего слоя $y_i^{(q-1)}$.

Что касается первого множителя в (2.20), он легко раскладывается следующим образом:

$$\frac{\partial E}{\partial y_j} = \sum_r \frac{\partial E}{\partial y_r} \frac{dy_r}{ds_r} \frac{\partial s_r}{\partial y_j} = \sum_r \frac{\partial E}{\partial y_r} \frac{dy_r}{ds_r} w_{jr}^{(q+1)}. \quad (2.21)$$

Здесь суммирование по r выполняется среди нейронов слоя $(q+1)$. Введя новую переменную

$$\delta_j^{(q)} = \frac{\partial E}{\partial y_j} \frac{dy_j}{ds_j}, \quad (2.22)$$

получим рекурсивную формулу для расчетов величин $\delta_j^{(q)}$ слоя q из величин $\delta_j^{(q+1)}$ более старшего слоя $(q+1)$

$$\delta_j^{(q)} = \left[\sum_r \delta_r^{(q+1)} w_{jr}^{(q+1)} \right] \frac{dy_j}{ds_j}. \quad (2.23)$$

Весовые коэффициенты нейронов выходного слоя изменяются на величину

$$\delta_j^{(Q)} = \left(y_j^Q - d_j \right) \frac{dy_j}{ds_j}. \quad (2.24)$$

Теперь можно записать (2.19) в раскрытом виде:

$$\Delta w_{ij}^{(q)} = -\eta \delta_j^{(q)} y_j^{(q-1)}. \quad (2.25)$$

Иногда для придания процессу коррекции весов некоторой инерционности, сглаживающей резкие скачки при перемещении по поверхности целевой функции, (2.25) дополняется значением изменения веса на предыдущей итерации:

$$\Delta w_{ij}^{(q)}(t) = -\eta \left(\mu \Delta w_{ij}^{(q)}(t-1) + (1-\mu) \delta_j^{(q)} y_j^{(q-1)} \right), \quad (2.26)$$

где μ – коэффициент инерционности; t – номер текущей итерации.

Таким образом, алгоритм обучения нейронной сети с помощью процедуры обратного распространения ошибки строится следующим образом.

ШАГ 1. Подать на входы сети один из возможных образов и в режиме обычного функционирования нейронной сети рассчитать значение сигнала:

$$s_j^{(q)} = \sum_{j=0}^L y_j^{(q-1)} w_{ij}^{(q)}, \quad (2.27)$$

где L – число нейронов в слое $(q-1)$ с учетом нейрона с постоянным выходным состоянием +1, задающего смещение; $y_j^{(q-1)} w_{ij}^{(q)}$ – i -й вход нейрона j слоя q ,

$$y_j^{(q)} = f(s_j^{(q)}), \quad (2.28)$$

$$y_r^{(q)} = x_r, \quad (2.29)$$

где $f(\bullet)$ – сигмонд; x_r – r -я компонента вектора входного образа.

ШАГ 2. Рассчитать $\delta^{(Q)}$ для нейронов выходного слоя сети по формуле (2.24).

Рассчитать по формуле (2.25) или (2.26) изменения весов $\Delta w^{(Q)}$ слоя Q .

ШАГ 3. Рассчитать по формулам (2.23) и (2.25) (или (2.23) и (2.26)) соответственно $\delta^{(q)}$ и $\Delta w^{(Q)}$ для всех остальных слоев, $q = (Q-1) \dots 1$.

ШАГ 4. Скорректировать все веса в нейронной сети:

$$w_{ij}^{(q)}(t) = w_{ij}^{(q)}(t-1) + \Delta w_{ij}^{(q)}(t). \quad (2.30)$$

ШАГ 5. Если ошибка сети существенна, перейти на шаг 1. В противном случае – завершить обучение.

Нейронной сети на шаге 1 попеременно в случайном порядке предъявляются все тренировочные образы, чтобы сеть не забывала одни по мере запоминания других.

Из выражения (2.25) следует, что когда выходное значение $y_j^{(q-1)}$ стремится к нулю, эффективность обучения заметно снижается. При двоичных входных векторах в среднем половина весовых коэффициентов не будет корректироваться, поэтому область возможных значений выходов нейронов $(0, 1)$ желательно сдвинуть в пределы $(-0,5; 0,5)$, что достигается простыми модификациями логистических функций. Например, сигмоид с экспонентой преобразуется к виду

$$f(s) = -0,5 + \frac{1}{1 + e^{-as}}. \quad (2.31)$$

В заключение рассмотрим вопрос о емкости нейронной сети, т.е. числа образов, предъявляемых на ее входы, которые она способна научиться распознавать. Для сети с числом слоев более двух, этот вопрос остается открытым. Для сетей с двумя слоями емкость сети C_d оценивается следующим образом:

$$\frac{L_w}{m} < C_d < \frac{L_w}{m} \log\left(\frac{L_w}{m}\right), \quad (2.32)$$

где L_w – число подстраиваемых весов; m – число нейронов в выходном слое.

Выражение (2.32) получено с учетом некоторых ограничений. Во-первых, число входов n и нейронов в скрытом слое L должно удовлетворять неравенству $(n+L) > m$. Во-вторых, $L_w/m > 1000$. Однако приведенная оценка выполнена для сетей с пороговыми активационными функциями нейронов, в то время как емкость сетей с гладкими активационными функциями обычно больше. Кроме того, с помощью выражения (2.32) можно получить оценку емкости для всех входных образов, которые могут быть представлены n входами. В действительности распределение входных образов, как правило, обладает некоторой регулярностью, что позволяет нейронной сети проводить обобщение и, таким образом, увеличивать реальную емкость. Так как распределение образов в общем случае заранее не известно, можно говорить о реальной емкости только предположительно.

Вопрос о емкости нейронной сети тесно связан с вопросом о требуемой мощности выходного слоя сети, выполняющего окончательную клас-

сификацию образов. Например, для разделения множества входных образов на два класса достаточно одного выходного нейрона. При этом каждый логический уровень («1» и «0») будет обозначать отдельный класс. На двух выходных нейронах с пороговой функцией активации можно закодировать уже четыре класса. Для повышения достоверности классификации желательно ввести избыточность путем выделения каждому классу одного нейрона в выходном слое или, что еще лучше, нескольких, каждый из которых обучается определять принадлежность образа к классу со своей степенью достоверности, например: высокой средней и низкой. Такие нейронные сети позволяют проводить классификацию входных образов, объединенных в нечеткие (размытые или пересекающиеся) множества. Это свойство приближает подобные сети к реальным условиям функционирования биологических нейронных сетей.

Рассматриваемая нейронная сеть имеет несколько «узких мест». Во-первых, в процессе обучения большие положительные или отрицательные значения весов могут сместить рабочую точку на сигмоидах нейронов в область насыщения. Малые величины производной от логистической функции приведут в соответствии с (2.22) и (2.23) к остановке обучения, что парализует сеть. Во-вторых, применение метода градиентного спуска не гарантирует нахождения глобального минимума целевой функции. Это тесно связано с вопросом выбора скорости обучения. Приращения весов и, следовательно, скорость обучения для нахождения экстремума должны быть бесконечно малыми, однако в этом случае обучение будет происходить неприемлемо медленно. С другой стороны, слишком большие коррекции весов могут привести к постоянной неустойчивости процесса обучения. Поэтому в качестве коэффициента скорости обучения η обычно выбирается число меньше 1 (например 0,1), которое постепенно уменьшается в процессе обучения. Кроме того, для исключения случайных попаданий сети в локальные минимумы иногда, после стабилизации значений весовых коэффициентов, η кратковременно значительно увеличивают, чтобы начать градиентный спуск из новой точки. Если повторение этой процедуры несколько раз приведет сеть в одно и то же состояние, можно предположить, что найден глобальный минимум.

Существует другой метод исключения локальных минимумов и парализации сети, заключающийся в применении стохастических нейронных сетей.

Таким образом, из вышесказанного следует, что в алгоритме обратного распространения вычисляется вектор градиента поверхности ошибок. Этот вектор указывает направление кратчайшего спуска по поверхности из текущей точки, движение по которому приводит к уменьшению ошибки. Последовательность уменьшающихся шагов приведет к минимуму того или иного типа. Основную трудность при этом представляет вопрос подбора длины шагов.

При большой величине шага сходимость будет более быстрой, но имеется опасность перепрыгнуть через решение или в случае сложной формы поверхности ошибок уйти в неправильном направлении, как например, продвигаясь по узкому оврагу с крутыми склонами, прыгая с одной его стороны на другую. Напротив, при небольшом шаге и верном направлении потребуется очень много итераций. На практике величина шага берется пропорциональной крутизне склона, так что алгоритм замедляет ход вблизи минимума. Правильный выбор скорости обучения зависит от конкретной задачи и обычно определяется опытным путем.

Алгоритм минимизации может видоизменяться таким образом, чтобы имелась возможность включать слагаемое импульса (или инерции). Это способствует продвижению в фиксированном направлении, поэтому если было сделано несколько шагов в одном и том же направлении, то алгоритм увеличивает скорость, что иногда позволяет избежать локального минимума, а также быстрее проходить плоские участки.

На каждом шаге алгоритма на вход сети поочередно подаются все обучающие примеры, реальные выходные значения сети сравниваются с требуемыми значениями и вычисляется ошибка. Значение ошибки, а также градиента поверхности ошибок используется для корректировки весов, после чего все действия повторяются. Процесс обучения прекращается либо когда пройдено определенное количество итераций, либо когда ошибка достигнет некоторого определенного малого уровня, либо когда ошибка перестанет уменьшаться.

Рассмотрим более подробно проблемы обобщения и переобучения нейронной сети. Обобщение – это способность нейронной сети давать точный прогноз на данных, не принадлежащих исходному обучающему множеству. Переобучение же представляет собой чрезмерно точную подгонку, которая имеет место, если алгоритм обучения работает слишком долго, а сеть слишком сложна для такой задачи или для имеющегося объема данных.

Предположим, что необходимо решить задачу аппроксимации некоторой зависимости не нейронной сетью, а посредством полиномов. Графики полиномов могут иметь различную форму, причем, чем выше степень и число членов, тем более сложной может быть эта форма. Для исходных данных можно подобрать полиномиальную кривую (модель) и получить таким образом объяснение имеющейся зависимости. Данные могут быть зашумлены, поэтому нельзя считать, что лучшая модель в точности проходит через все имеющиеся точки. Полином низкого порядка может лучше объяснять имеющуюся зависимость, однако быть недостаточно гибким средством для аппроксимации данных, в то время как полином высокого порядка может оказаться слишком гибким, но будет точно следовать данным, принимая форму, не соответствующую реальной зависимости.

Нейронные сети сталкиваются с такими же трудностями. Сети с большим числом весов моделируют более сложные функции и, следовательно, склонны к переобучению. Сети с небольшим числом весов могут оказаться недостаточно гибкими, чтобы смоделировать имеющиеся зависимости. Например, сеть без скрытых слоев моделирует лишь обычную линейную функцию. Почти всегда более сложная сеть дает меньшую ошибку, но это может свидетельствовать не о хорошем качестве модели, а о переобучении сети.

Выход состоит в использовании контрольной кросс-проверки. Для этого резервируется часть обучающей выборки, которая используется не для обучения сети по алгоритму обратного распространения ошибки, а для независимого контроля результата в ходе алгоритма. В начале работы ошибка сети на обучающем и контрольном множествах будет одинаковой. По мере обучения сети ошибка обучения убывает, как убывает и ошибка на контрольном множестве. Если же контрольная ошибка перестала убывать или даже стала расти, это указывает на то, что сеть начала слишком близко аппроксимировать данные (переобучилась) и обучение следует остановить. Если это случилось, то следует уменьшить число скрытых элементов и/или слоев, так как сеть является слишком мощной для данной задачи. Если же обе ошибки (обучения и кросс-проверки) не достигнут достаточного малого уровня, то переобучения, естественно, не произошло, а сеть, напротив, является недостаточно мощной для моделирования имеющейся зависимости.

Описанные проблемы приводят к тому, что при практической работе с нейронными сетями приходится экспериментировать с большим числом

различных сетей, порой обучая каждую из них по несколько раз и сравнивая полученные результаты. Главным показателем качества результата является контрольная ошибка. При этом в соответствии с общесистемным принципом из двух сетей с приблизительно равными ошибками контроля имеет смысл выбрать более простую.

Необходимость многократных экспериментов приводит к тому, что контрольное множество начинает играть ключевую роль в выборе модели и становится частью процесса обучения. Тем самым ослабляется его роль как независимого критерия качества модели. При большом числе экспериментов существует большая вероятность выбрать удачную сеть, дающую хороший результат на контрольном множестве. Однако для того чтобы придать окончательной модели должную надежность, часто (когда объем обучающих примеров это позволяет) поступают следующим образом: резервируют тестовое множество примеров. Итоговая модель тестируется на данных из этого множества, чтобы убедиться, что результаты, достигнутые на обучающем и контрольном множествах примеров, реальны, а не являются артефактами процесса обучения. Разумеется, для того чтобы хорошо выполнять свою роль, тестовое множество должно быть использовано только один раз: если его использовать повторно для корректировки процесса обучения, то оно фактически превратится в контрольное множество.

С целью ускорения процесса обучения сети предложены многочисленные модификации алгоритма обратного распространения ошибки, связанные с использованием различных функций ошибки, процедур определения направления и величин шага.

1. *Функции ошибки:*

- интегральные функции ошибки по всей совокупности обучающих примеров;
- функции ошибки целых и дробных степеней.

2. *Процедуры определения величины шага на каждой итерации:*

- дихотомия;
- итерационные соотношения;
- отжиг.

3. *Процедуры определения направления шага с использованием:*

- матрицы производных второго порядка (метод Ньютона);
- направлений на нескольких шагах.

Алгоритм обучения многослойных сетей без учителя

Рассмотренный алгоритм обратного распространения ошибки подразумевает наличие некоторого внешнего звена, предоставляющего нейронной сети, кроме входных, целевые выходные образы. Алгоритмы, основанные на подобной концепции, называются алгоритмами обучения с учителем.

Для их успешного функционирования необходимо наличие экспертов, задающих на предварительном этапе для каждого входного образа эталонный выходной образ.

Процесс обучения сети без учителя, как и в случае обучения с учителем, заключается в подстраивании весов синапсов. Некоторые алгоритмы, правда, изменяют и структуру сети, т. е. количество нейронов и их взаимосвязи, но такие преобразования правильнее назвать более широким термином – *самоорганизацией*. Очевидно, что подстройка весов синапсов может проводиться только на основании информации о состоянии нейронов и уже имеющихся весовых коэффициентов. На этом, в частности, по аналогии с известными принципами самоорганизации нервных клеток, построены алгоритмы Хебба.

Сигнальный метод обучения Хебба заключается в изменении весов по следующему правилу:

$$w_{ij}(t) = w_{ij}(t-1) + \alpha y_i^{(q-1)} y_j^q, \quad (2.33)$$

где $y_i^{(q-1)}$ – выходное значение нейрона i -го слоя ($q-1$); y_j^q – выходное значение нейрона j -го слоя q ; $w_{ij}(t)$ и $w_{ij}(t-1)$ – весовой коэффициент синапса, соединяющего эти нейроны, на итерациях t и $(t-1)$ соответственно; α – коэффициент скорости обучения. При обучении по данному методу усиливаются связи между возбужденными нейронами.

Существуют также и дифференциальный метод обучения Хебба, определяемый соотношением:

$$w_{ij}(t) = w_{ij}(t-1) + \alpha (y_i^{(q-1)}(t) - y_j^{(q-1)}(t-1)) [y_i^{(q)}(t) - y_j^{(q)}(t-1)], \quad (2.34)$$

где $y_i^{(q-1)}(t)$ и $y_j^{(q-1)}(t-1)$ – выходное значение нейрона i -го слоя ($q-1$) соответственно на итерациях t и $(t-1)$; $y_i^{(q)}(t)$ и $y_j^{(q)}(t-1)$ – выходное значение нейрона j -го слоя q . Как видно из формулы (2.34), более интенсивно обучаются синапсы, соединяющие нейроны, выходы которых наиболее динамично изменились в сторону увеличения.

Полный алгоритм обучения без учителя с применением вышеприведенных формул состоит из следующих шагов.

ШАГ 1. На этапе инициализации всем весовым коэффициентам присваиваются небольшие случайные значения.

ШАГ 2. На входы сети подается входной образ, и сигналы возбуждения распространяются по всем слоям согласно принципам классических сетей прямого распространения (feedforward). При этом для каждого нейрона рассчитывается взвешенная сумма его входов, к которой затем применяется активационная функция нейрона, в результате чего определяется его выходное значение y_i^q , $i = 1 \dots L_q$, где L_q – число нейронов в слое q ; $q = 1 \dots Q$; Q – число слоев в сети.

ШАГ 3. На основании полученных выходных значений нейронов в соответствии с формулами (2.33), (2.34) изменяются весовые коэффициенты.

ШАГ 4. Цикл с шага 2, пока выходные значения сети не стабилизируются с заданной точностью. Применение этого способа определения момента завершения обучения, отличного от использовавшегося для сети обратного распространения, обусловлено тем, что подстраиваемые значения синапсов фактически не ограничены. На шаге 2 цикла попеременно предъявляются все образы из входного набора.

Следует отметить, что вид откликов на каждый класс входных образов заранее неизвестен и представляет собой произвольное сочетание состояний нейронов выходного слоя, обусловленное случайным распределением весов на стадии инициализации. Вместе с тем сеть способна обобщать схожие образы, относя их к одному классу. Тестирование обученной сети позволяет определить топологию классов в выходном слое. Для приведения откликов обученной сети к удобному представлению можно дополнить сеть одним слоем, который, например, по алгоритму обучения однослойного персептрона необходимо заставить отображать выходные реакции сети в требуемые образы.

Другой алгоритм обучения без учителя – алгоритм Кохонена – предусматривает подстройку синапсов на основании их значений на предыдущей итерации:

$$w_{ij}(t) = w_{ij}(t-1) + \alpha [y_i^{(q-1)} - w_{ij}(t-1)]. \quad (2.35)$$

Из выражения (2.35) видно, что обучение сводится к минимизации разницы между входными сигналами нейрона, поступающими с выходов

нейронов предыдущего слоя $y_i^{(q-1)}$, и весовыми коэффициентами его синапсов.

Полный алгоритм обучения имеет приблизительно такую же структуру, как в методах Хебба, но на шаге 3 из всего слоя выбирается нейрон, значение синапсов которого минимально отличается от входного образа, и подстройка весов по формуле (2.35) проводится только для него. Эта так называемая аккредитация может сопровождаться торможением всех остальных нейронов слоя и введением выбранного нейрона в насыщение. Выбор такого нейрона может осуществляться, например, расчетом скалярного произведения вектора весовых коэффициентов с вектором входных значений.

Другой вариант состоит в расчете расстояния D_j между этими векторами в R -мерном пространстве:

$$D_j = \sqrt{\sum_{i=1}^R (y_i^{(q-1)} - w_{ij})^2}, \quad (2.36)$$

где R – размерность векторов; j – индекс нейронов в слое q ; i – индекс суммирования по нейронам слоя $(q-1)$; w_{ij} – вес синапса, соединяющего нейроны; выходы нейронов в слое $(q-1)$ являются входными значениями для слоя q .

В данном случае выбирается нейрон с наименьшим D_j . Иногда слишком часто получающие аккредитацию нейроны принудительно исключаются из рассмотрения, чтобы уравнивать права всех нейронов в слое. Простейший вариант такого алгоритма заключается в торможении только что выбранного нейрона.

С целью сокращения длительности процесса обучения при использовании алгоритма Кохонена существует практика нормализации входных образов и начальных значений весовых коэффициентов на стадии инициализации в соответствии с выражениями

$$w_0 = 1/\sqrt{n}, \quad (2.37)$$

$$x'_i = \frac{x_i}{\sqrt{\sum_{j=1}^n x_j^2}}, \quad (2.38)$$

где x_i – i -й компонент вектора входного образа или вектора весовых коэффициентов; n – размерность вектора.

Инициализация весовых коэффициентов случайными значениями может привести к тому, что различные классы, которым соответствуют плотно распределенные входные образы, сольются или, наоборот, раздробятся на дополнительные подклассы в случае близких образов одного и того же класса. Чтобы избежать такой ситуации, используется метод выпуклой комбинации. Суть его сводится к тому, что входные нормализованные образы подвергаются преобразованию:

$$x_i = \alpha(t)x_i + (1 - \alpha(t))\frac{1}{\sqrt{n}}, \quad (2.39)$$

где $\alpha(t)$ – коэффициент, изменяющийся в процессе обучения от 0 до 1, в результате чего вначале на входы сети подаются практически одинаковые образы, а с течением времени они все больше сходятся к исходным.

После выбора из слоя q нейрона j с минимальным расстоянием D_j по формуле (2.36) производится обучение по формуле (2.35) не только этого нейрона, но и его соседей, расположенных в окрестности Ω . Величина Ω для первых итераций очень большая, так что обучаются все нейроны, но с течением времени она уменьшается до нуля. Таким образом, чем ближе окончание обучения, тем точнее определяется группа нейронов, отвечающих каждому классу образов.

Для того чтобы многослойная нейронная сеть реализовывала заданное обучающей выборкой отображение, она должна иметь достаточное число нейронов в скрытых слоях. В настоящее время нет формул для точного определения необходимого числа нейронов в сети по заданной обучающей выборке. Однако предложены способы настройки числа нейронов в процессе обучения, которые обеспечивают построение нейронной сети для решения задачи и дают возможность избежать избыточности. Способы настройки числа нейронов можно разделить на две группы: *алгоритмы сокращения* (pruning algorithms) и *конструктивные алгоритмы* (constructive algorithms).

В начале работы алгоритма обучения с сокращением число нейронов в скрытых слоях сети заведомо избыточно. Затем из нейронной сети постепенно удаляются синапсы и нейроны. Существуют два подхода к реализации алгоритмов сокращения.

1. Метод штрафных функций

В целевую функцию алгоритма обучения вводятся штрафы C за то, что значения синаптических весов отличны от нуля, например

$$C = \sum_{i=1}^L \sum_{j=1}^n w_{ij}^2, \quad (2.40)$$

где w_{ij} – синаптический вес; i – номер нейрона; j – номер входа; L – число нейронов скрытого слоя; n – размерность входного сигнала.

2. Метод проекций

Синаптический вес обнуляется, если его значение попало в заданный диапазон:

$$w_{ij} = \begin{cases} 0, & |w_{ij}| \leq \varepsilon, \\ w_{ij}, & |w_{ij}| > \varepsilon, \end{cases} \quad (2.41)$$

где ε – некоторая константа.

Алгоритмы сокращения имеют по крайней мере два недостатка:

- нет методики определения числа нейронов скрытых слоев, которое является избыточным, поэтому перед началом работы алгоритма нужно задать это число;

- в процессе работы алгоритма сеть содержит избыточное число нейронов, поэтому обучение идет медленно.

В конструктивных алгоритмах используется методика обучения многослойных нейронных сетей, включающая в себя следующие шаги.

ШАГ 1. Выбор начального числа нейронов в скрытых слоях.

ШАГ 2. Инициализация сети, заключающаяся в присваивании синаптическим весам и смещениям сети случайных значений из заданного диапазона.

ШАГ 3. Обучение сети по заданной выборке.

ШАГ 4. Завершение в случае успешного обучения. Если сеть обучить не удалось, то число нейронов увеличивается и повторяются шаги со второго по четвертый.

В конструктивных алгоритмах число нейронов в скрытых слоях сети в начале обучения также мало и постепенно увеличивается. В отличие от этой методики, в конструктивных алгоритмах сохраняются навыки, приобретенные сетью до увеличения числа нейронов.

Конструктивные алгоритмы различаются правилами задания значений параметров в новых, добавленных в сеть нейронов:

- значения параметров являются случайными числами из заданного диапазона;
- значения синаптических весов нового нейрона определяют путем *расщепления* (splitting) одного из старых нейронов.

Первое правило не требует значительных вычислений, однако его использование приводит к некоторому увеличению значения функции ошибки после каждого добавления нового нейрона. В результате случайного задания значений параметров новых нейронов может появиться избыточность в числе нейронов скрытого слоя. Расщепление нейронов лишено двух указанных недостатков. Суть алгоритма расщепления проиллюстрирована на рис 2.12.

На рисунке показан вектор весов нейрона скрытого слоя на некотором шаге обучения и векторы изменения весов, соответствующие отдельным обучающим примерам. Векторы изменений имеют два преимущественных направления и образуют в пространстве область, существенно отличающуюся от сферической. Суть алгоритма заключается в выявлении и расщеплении таких нейронов. В результате расщепления вместо одного исходного в сети оказывается два нейрона. Первый из этих нейронов имеет вектор весов, представляющий собой сумму вектора весов исходного нейрона и векторов изменений весов одного из преимущественных направлений. В результате суммирования векторов изменений весов другого преимущественного направления и вектора весов исходного нейрона определяются синаптические веса второго нового нейрона.

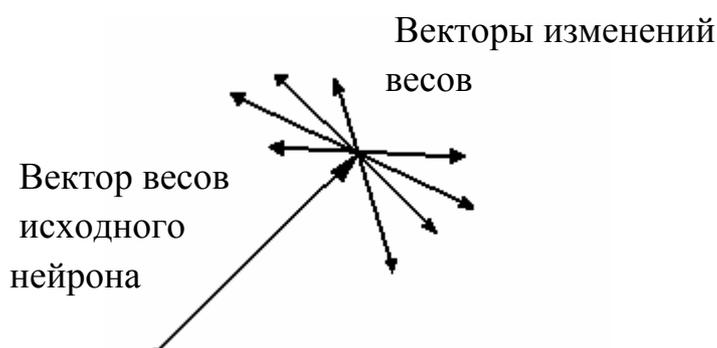


Рис. 2.12. Вектор весов нейрона скрытого слоя

Расщеплять нейроны, векторы изменений которых имеют два преимущественных направления, необходимо потому, что наличие таких ней-

ронов приводит к осцилляциям при обучении методом обратного распространения. При обучении методом с интегральной функцией ошибки наличие таких нейронов приводит к попаданию в локальный минимум с большим значением ошибки.

Алгоритм расщепления включает в себя:

- построение ковариационной матрицы векторов изменений синаптических весов;

- вычисление собственных векторов и собственных значений полученной матрицы с помощью итерационного алгоритма Ойа (Oja), в соответствии с которым выполняются стохастический градиентный подъем и ортогонализация Грамма – Шмидта.

Недостатком алгоритма является экспоненциальный рост времени вычислений при увеличении размерности сети.

Для преодоления указанного недостатка предложен *упрощенный алгоритм расщепления*, который не требует значительных вычислений. Общее число нейронов в сети, построенной с помощью этого алгоритма по заданной обучающей выборке, может быть несколько больше, чем у сети, построенной с помощью исходного алгоритма.

В упрощенном алгоритме для расщепления выбирается нейрон с наибольшим значением функционала:

$$F_i = \frac{\sum_{k=1}^N |\delta w_i^k|}{\left| \sum_{k=1}^N \delta w_i^k \right|}, \quad (2.42)$$

где δw – вектор изменений синаптических весов нейрона; i – номер нейрона; $i = 1 \dots L$, L – число нейронов; k – номер обучающего примера; N – число примеров в обучающей выборке.

Таким образом, в качестве критерия выбора нейрона для расщепления используется отношение суммы длин векторов изменений синаптических весов нейрона, соответствующих различным обучающим примерам, к длине суммы этих векторов.

В результате расщепления вместо исходного нейрона в сеть вводятся два новых нейрона. Значение каждого синаптического веса нового нейрона есть значение соответствующего веса старого нейрона плюс некоторый небольшой шум. Величины весов связей выходов новых нейронов и нейронов следующего слоя равны половине величин весов связей исходного нейрона с соответствующими весами следующего слоя. Упрощенный алгоритм, как и исходный, гарантирует, что функция ошибки после расщепления увеличиваться не будет.

Кроме описанных способов выбора нейронов для расщепления, может быть использован анализ чувствительности, в процессе которого строятся матрицы Гессе для вторых производных функции ошибки по параметрам сети. По величине модуля второй производной судят о важности значения данного параметра для решения задачи. Параметры с малыми значениями вторых производных обнуляют. Анализ чувствительности требует больших вычислительных ресурсов.

Контрольные вопросы и задания

1. Как называется модель нервной клетки?
2. Перечислите основные положения теории формальных нейронов.
3. Изобразите электрическую модель нейрона.
4. Приведите зависимость выходной частоты от входного тока для модели нейрона.
5. Какой вид имеет математическая модель нейрона?
6. Из каких элементов состоит искусственный нейрон?
7. Дайте определение понятия функции активации нейрона.
8. Приведите примеры активационных функций искусственных нейронов.
9. Перечислите преимущества сигмоидальной активационной функции.
10. В чем отличие входного нейрона от промежуточного нейрона?
11. Назовите и поясните типы нейронных сетей.
12. Изобразите архитектуру полносвязных нейронных сетей, многослойных сетей с последовательными связями, слабосвязных сетей. Охарактеризуйте названные типы нейронных сетей.
13. В чем отличие между монотонными нейронными сетями и сетями без обратных связей?

14. Приведите структуру многослойной нейронной сети прямого пространства.
15. Поясните суть процесса обучения нейронной сети. Сформулируйте задачу обучения сети.
16. Назовите и охарактеризуйте методы решения задачи многомерной оптимизации. В чем заключается связь этих методов с задачей обучений нейронной сети.
17. Опишите процесс функционирования многослойного персептрона.
18. Докажите, что однослойный персептрон, состоящий из одного нейрона с двумя входами, не может реализовать логическую функцию «Исключающее ИЛИ».
19. Как называются функции, которые не реализуются однослойным персептроном?
20. Приведите и поясните алгоритм обучения с учителем однослойного персептрона.
21. Докажите сходимостью процедуры обучения однослойного персептрона.
22. Назовите основные методы ускорения процесса обучения нейронной сети.
23. Поясните суть алгоритма обучения многослойных нейронных сетей без учителя.

Глава 3. МОДЕЛИРОВАНИЕ БИОЛОГИЧЕСКОЙ ПАМЯТИ

3.1. Организация биологической памяти на клеточном уровне

Деятельность всех механизмов нервной системы человека и высших животных связана с функционированием и взаимодействием клеток (нейронов), из которых эта система построена. Память человека по современным представлениям – это результат сложного взаимодействия больших популяций нейронов, принадлежащих к различным отделам нервной системы; кроме того, отдельные элементарные процессы запоминания могут осуществляться и на уровне отдельного нейрона. Реальный нейрон является клеточным элементом в системе нервного механизма, но в то же самое время он сам представляет собой довольно сложную систему, существование и деятельность которой поддерживаются определенной внутриклеточной организацией.

Каждый нейрон представляет собой интегрирующую систему со многими входами и одним выходом. На одном и том же нейроне происходит интегрированная обработка многочисленных разнородных возбуждений. Временное суммирование возбуждающих и тормозящих воздействий является одним из видов памяти на уровне отдельного нейрона. Современная нейрофизиология положила в основу объяснения интегрирования суммирование на мембране нейрона всех субсинаптических потенциалов, возникающих в данный момент, и воздействие этой суммы на триггерные механизмы генераторного пункта нейрона. Эта позиция является главной на современном этапе развития нейрофизиологии.

Рассматривая запоминаящие возможности нейрона, следует отметить своеобразный вид памяти, который связан с наличием у нейрона так называемой фазы абсолютной рефрактерности. В течение некоторого периода времени после возбуждения нейрона невозможно вызвать новое появление потенциала действия никаким возбуждающим воздействием даже на синапсы детонаторной группы. Это явление называется абсолютной рефрактерностью нейрона. Такая нечувствительность объясняется, видимо, необ-

ходимостью компенсации энергетических затрат, связанных с возбуждением нейрона; происходит эта компенсация за счет энергии, выделяющейся при обмене веществ. Функциональное значение фазы абсолютной рефрактерности нейрона состоит в том, что в нейронной сети в течение определенного периода времени хранится информация о том, что данный нейрон возбуждался и что для нормальной работы сети возбуждение этого нейрона пока еще недопустимо. Фаза абсолютной рефрактерности является, по видимому, одним из факторов, препятствующих лавинообразному нарастанию процессов возбуждения и торможения во всех нейронах сети и обеспечивающих некоторое динамическое равновесие процессов, происходящих в сети.

По окончании абсолютной рефрактерности возбудимость нейрона не сразу восстанавливается; в течение некоторого времени, называемого фазой относительной рефрактерности, она остается относительно низкой и плавно увеличивается до исходного уровня. После завершения фазы относительной рефрактерности наблюдается период повышенной экзальтации - возбудимость нейрона становится выше исходной. Функциональное значение фазы относительной рефрактерности и периода повышенной экзальтации в настоящее время еще не ясно.

Особый вид памяти на уровне отдельного нейрона связан с изменением эффективности синапса в процессе его длительного функционирования. Этому виду памяти современная нейрофизиология придает большое значение, связывая его с некоторыми видами человеческой памяти. Электрофизиологическими исследованиями в периферийной нервно-мышечной системе было обнаружено явление, получившее название постактивационного усиления, или посттетанической потенции (ПТП).

Суть явления состоит в том, что после длительного возбуждения нейрона по одному входу (т.е. через один синапс) интенсивность его реакции увеличивается. Постактивационный эффект в значительной степени зависит от характера активации нейрона. При короткой стимуляции (сотни миллисекунд) ПТП развивается только при сравнительно высокой частоте воздействия (более 100 Гц), а постактивационный эффект исчезает через несколько секунд после прекращения стимуляции. Длительная активация вызывает ПТП при меньших частотах стимуляции (до 100 Гц), постактивационный эффект в этом случае имеет место в течение нескольких минут.

С функциональной точки зрения ПТП, безусловно, можно классифицировать как запоминание. Активация является записью информации, одиночные тестовые воздействия можно сопоставить с сигналом считывания, в выходном сигнале содержится информация о параметрах (времени действия и частоте) активирующего сигнала. Следует помнить только о том, что рассмотренные процессы записи и считывания информации не соответствуют физиологической норме, хотя субстрат, использованный для записи, хранения и воспроизведения информации, находится в своем нормальном физиологическом состоянии.

Подобные экспериментальные исследования, связанные прежде всего с развитием ПТП при моносинаптической передаче сигналов, позволяют сделать вывод о том, что возникновение ПТП связано с процессами в пресинаптических окончаниях. Было также установлено, что при наличии на поверхности тела нейрона нескольких синапсов, предыстория воздействия на нейрон через каждый отдельный синапс не влияет на процессы, возникающие при использовании других синапсов.

Таким образом, можно считать экспериментально установленным факт, что в основе ПТП лежат длительные устойчивые изменения в эффективности синапсов и что память при развитии ПТП локализуется именно в синапсе.

Во всех работах, посвященных нервной системе, конечно, речь идет о нейронах. Однако нейроны не существуют в пространстве сами по себе; они занимают ничтожно малую по объему часть нервной ткани, основную массу которой составляют глиальные клетки, образующие нейроглию. Более ста миллиардов клеток нейроглии непосредственно прилегают к десяти миллиардам нейронов и обволакивают их. Привлекает внимание одна особенность ткани: в ней практически нет свободного межклеточного пространства, нет никаких полостей между клетками нейроглии и нейронами. Когда в нейроне возникает импульс, наблюдается обмен ионов между внутренней и внешней средами клетки; при этом внешней средой обязательно оказывается клетка нейроглии. Значит эти клетки никак не могут играть пассивную роль; нервная активность возникает в результате взаимодействия клеток двух типов. При исследовании клеток нейроглии был зарегистрирован потенциал покоя, подобный потенциалу покоя нейрона.

Существует гипотеза о роли глиальных клеток в хранении информации, в соответствии с которой считают, что глия программирует деятельность нервных клеток, формируя поведение, приспособление к внешней

обстановке, к изменениям внешней среды. Роль глиальных клеток можно сравнить с компьютерной программой: глия «указывает» нейронам порядок и последовательность их действий.

Несмотря на правдоподобность, гипотеза о роли глиальных клеток в хранении информации из-за недостаточности экспериментальных данных большого распространения в настоящее время не получила.

3.2. Ассоциативная память нейронных сетей

В биологических системах, обладающих памятью, изменение нервной активности системы под влиянием внешних раздражителей зависит от предшествующих событий и от информации, хранящейся в памяти. Процесс запоминания связан с образованием следа (энграммы) в мозговых структурах. Поток нервных импульсов, несущих информацию о запоминаемом объекте, проходит через нейронные сети, возбуждая на своем пути нервные клетки, из которых формируется нейронный след. Проторенный нервный путь обладает меньшим сопротивлением по отношению к другим возможным путям. Повышение производительности возникшего нейронного следа возможно вследствие свойства нейронов достаточно быстро адаптироваться к повторно проходящим нервным импульсам. Механизмы памяти обеспечивают длительное сохранение увеличенной проводимости нейронов, вовлеченных в образованный след.

Следы памяти, хранящие образы объектов, отражены в сложных параллельно-последовательных нейронных сетях, обладающих большой избыточностью. В организованных случайным образом нейронных сетях следы памяти распределяются по пространству мозга случайно.

Ситуация еще больше усложняется тем, что одни и те же нейроны участвуют в хранении образов различных запоминаемых объектов. Это означает, что след, возникший при запоминании одного объекта информации, может иметь общие звенья нейронной сети со следами от других объектов. Поэтому нельзя определенно указать, в каком участке мозга будет находиться след конкретного объекта информации – образа.

В этом случае механизм доступа к информации базируется не на указании места хранения информации в логико-запоминающей среде, а на анализе свойств самой искомой информации.

В биологических системах обработки данных таким механизмом является механизм ассоциаций. Термин «ассоциация» впервые был введен Дж. Локком и определен как «связь, возникающая при определенных условиях между двумя или более психическими образованиями – ощущениями, актами, восприятиями, идеями».

Применительно к системам обработки данных, в том числе к искусственным нейронным сетям, ассоциация трактуется как взаимосвязь между информацией (образом) на входе логико-запоминающей среды и информацией (образом), хранящейся в логико-запоминающей среде. Способ доступа к информации в запоминающей среде, базирующийся на механизме ассоциации, получил название *ассоциативного способа доступа*. Ассоциативный способ доступа к информации обеспечивает:

- практически одновременный доступ ко всей хранящейся в памяти информации;
- относительную независимость времени поиска информации от емкости памяти;
- внесение элемента обработки информации непосредственно в процесс самого доступа;
- обработку информации непосредственно в среде ее хранения.

Эти, а также ряд других отличительных особенностей ассоциативного доступа к информации делает его чрезвычайно перспективным в системах обработки данных.

Существуют различные концепции ассоциативной памяти. Однако все они предполагают наличие следующих элементов:

- логико-запоминающей среды, являющейся носителем информации;
- множества записанных в памяти информационных объектов;
- структуры взаимосвязей между информационными объектами;
- механизма информационных взаимодействий записанных объектов в логико-запоминающей среде.

Вышеперечисленные элементы концепции ассоциативной памяти позволяют определить основной подход, в соответствии с которым ассоциации между информационными объектами (образами) трактуются как некая абстрактная структура взаимозависимостей (отношений), неявно закодированная в информационных объектах и в соответствующих связях между ними или в формах их представлений.

Эти отношения содержат компоненты двух типов, первые из которых задают сами информационные объекты, а вторые – вид отношений. Признаки этих отношений могут характеризовать свойства объектов, действия над ними, подчиненность, временные признаки и т.д. Очевидно, что такое представление ассоциации – наиболее простая конструкция, на основе которой можно построить структуры отношений произвольной сложности.

В зависимости от условий формирования отношений между ассоциируемыми объектами ассоциации могут устанавливаться по критериям сходства объекта, контраста, по смежности проявления объектов во времени или в пространстве, а также в рамках определенной совокупности свойств, например, при обеспечении заданных пространственно-временных соотношений.

Логика взаимодействий между информационными объектами может быть реализована на основе двух концепций:

- формирование отношений ассоциаций между однородными объектами;
- концепция «составного отношения», где отношения ассоциаций устанавливаются между качественно различными объектами.

Вид связи между ассоциируемыми объектами может быть различным:

- символная – связь между объектами устанавливается «на основании соглашения»;
- индексная – связь ассоциируется в силу существующих отношений между объектами;
- иконическая – связь между объектами устанавливается на основе фактического сходства;
- гибридная – сочетает особенности различных видов связи.

В зависимости от степени соответствия ассоциируемых объектов различают *автоассоциации* и *гетероассоциации*. Автоассоциации реализуются при условии соответствия соотносимых объектов. Причем объект отыскивается по его произвольным частям, имеющим большую или меньшую корреляцию с искомым объектом, или по его фрагментам в случае, если они достаточны для того, чтобы отличить этот объект от остальных. Для гетероассоциаций характерно то, что инициируемый объект структурно не соответствует любому из поисковых объектов и формируется как ответ на специфический ключевой объект.

Ассоциируемые объекты могут быть представлены либо прямыми, либо косвенными (непрямыми) ассоциациями. Прямые ассоциации по спо-

собу представления в виде функциональной зависимости могут инициироваться либо логически детерминированной последовательностью, либо на основе ассоциативной связи посредством прямых указателей. Представление непрямых ассоциаций в виде функциональной зависимости образуется на основе ассоциативных связей посредством перекрестных ссылок.

В контексте трактовки понятия ассоциации как структуры взаимозависимостей между информационными объектами оно отражает наличие взаимосвязей между данными и не имеет отношения к самому механизму хранения информации.

В рамках подхода, рассматривающего ассоциации как коллективные или интегральные изменения в нейронной сети (логико-запоминающей среде), ассоциативные свойства сети могут быть рассмотрены:

- во-первых, с точки зрения возможности коллективного доступа ко всей распределенной в нейронной сети информации, а также параллельной обработки и одновременного преобразования всех данных непосредственно в нейронной среде;

- во-вторых, с точки зрения практической реализации отношений между размещенными в нейронной сети, ассоциируемыми информационными объектами. В этом случае свойства сети могут существенным образом влиять на интерпретацию отношений между информационными объектами, позволяя по-новому подойти к исследованию этих объектов и взаимодействий между ними.

Именно этот подход позволяет выделить типы нейронных сетей, эффективно используемых для реализации различных задач ассоциативной памяти.

3.3. Модели ассоциативной памяти

Ассоциативная память может быть определена как система для записи, хранения, поиска, обработки и считывания информации, в которой данные (знания) об объекте могут быть инициализированы по заданному фрагменту этих данных (знаний), используемому в качестве поискового.

Исходя из этого определения, можно сформулировать решаемые ассоциативной памятью задачи:

- соотнесение поисковой информации с хранимой и дополнение ее (инициализация) до точного описания объекта, т.е. всей информации, которая доступна ассоциативной памяти;

- фильтрация (коррекция) поисковой информации относительно всего объема хранимой в ассоциативной памяти информации, выделение недостоверной и на основании оставшейся решение первой задачи.

Процессы, аналогичные биологическим механизмам запоминания и обработки информации, можно представить с помощью различных моделей ассоциативной памяти, позволяющих отобразить отношения (ассоциации) произвольной сложности между информационными объектами. Однако все эти отношения могут быть реализованы в виде простых конструкций – троек компонентов: упорядоченной пары информационных объектов O и V и типа отношения A . Одна из простейших моделей ассоциативной памяти для отображения таких отношений показана на рис. 3.1.

Модель состоит из ассоциативной логико-запоминающей среды (нейронной сети), связанной с двумя каналами ввода и одним каналом вывода информации. На этапе записи (обучения) из первого ввода на вход K подается входная информация, а по второму каналу – признаковая информация C , представляющая контекст, в котором входная информация записывается в память.

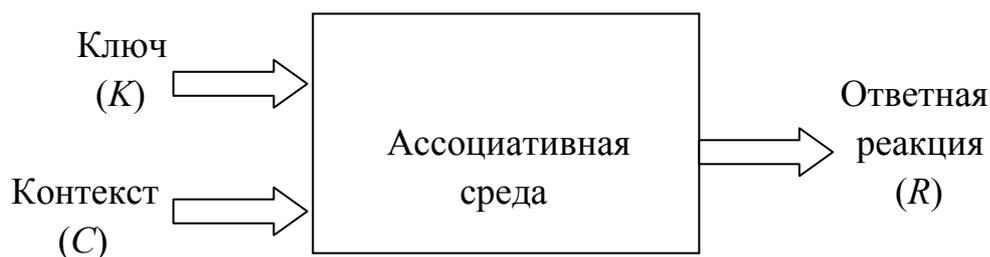


Рис. 3.1. Модель ассоциативной памяти

На этапе функционирования (считывания) при появлении ключа K (или его фрагмента) на выходе памяти формируется ответная реакция R , связанная с ключом K . Таким образом, записанная в память информация может быть получена по любым ее фрагментам, используемым в качестве поисковых. Задавая различный контекст C , можно точнее конкретизировать информацию, которую необходимо получить.

Рассмотрим на примере, каким образом должен быть организован процесс накопления и поиска информации в ассоциативной памяти, чтобы обеспечить цикличность процесса, при котором выбранный элемент информации становится ключом для поиска новой информации.

По трем входным каналам одновременно могут вводиться наборы значений (рис. 3.2). По первому каналу в момент времени t подается адресная информация $K(t)$, а по второму – признак $C(t)$. Отклик $R(t)$ по каналу обратной связи поддается также на вход ассоциативной среды. Выходной канал служит для выдачи информации.

При функционировании такой ассоциативной памяти ключи $K(t)$ и признаки $C(t)$ подаются через интервалы времени, соответствующие задержке канала обратной связи. Процесс работы памяти будем рассматривать в предположении, что тройка $[K(t), C(t), R(t-\Delta)]$ представляет собой единый статический образ, заданный в момент времени t , причем возможна его одновременная запись в памяти за одну операцию. Допустим также, что на этапе записи $R(t)$ и $K(t)$ одинаковы.



Рис. 3.2. Модель ассоциативной памяти с обратной связью

На этапе записи на входы ассоциативной памяти поступают $K(t)$ и $C(t)$, при этом на выходе формируется $R(t)$, идентичный $K(t)$. После этого с задержкой Δ на входе формируется $R(t-\Delta)$. Каждая новая тройка, появляющаяся на входах, записывается в память.

На этапе получения данных из ассоциативной памяти на вход подается ключ K , связанный с контекстной информацией C , после чего K можно снять с входа. В результате на выходе в качестве отклика появляется копия K . Когда на выходе памяти появится задержанный сигнал $R(t-\Delta)$, новым ключевым признаком становится пара (C, R) , приводящая к появлению на выходе следующего образа $R(t)$ и т.д. Таким образом, выбирается вся записанная последовательность образов вместе с контекстной информацией.

Рассмотренная системная модель реализует ассоциативную память, пригодную для записи и выборки структурированных знаний.

Модели ассоциативной памяти, реализуемые нейронными сетями, могут быть гораздо сложнее. Кроме того, память может иметь несколько входов и выходов, состоять из нескольких подсистем. Данные в одном канале могут породить контекстную информацию для другого канала. Этап записи может выполняться отдельно от выборки или быть совмещенным и т.д.

Нейронные сети Хопфилда

Нейронная сеть Хопфилда реализует существенное свойство автоассоциативной памяти – восстановление по искаженному (зашумленному) образу ближайшего к нему эталонного образа. В этом случае входной вектор используется как начальное состояние сети, и далее сеть эволюционирует согласно своей динамике. Причем любой пример, находящийся в области притяжения хранимого образа, может быть использован как указатель для его восстановления. Выходной (восстановленный) образ устанавливается, когда сеть достигает равновесия.

Структура сети Хопфилда приведена на рис. 3.3. Она состоит из одного слоя нейронов, число которых определяет число входов и выходов сети. Выход каждого нейрона соединен с входами всех остальных нейронов.

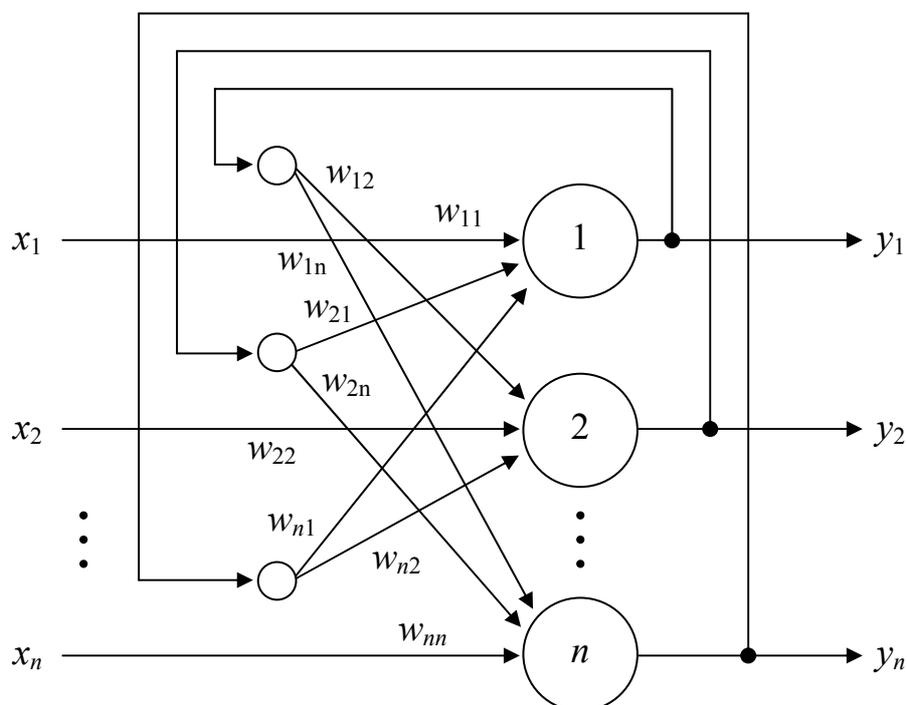


Рис. 3.3. Структура нейронной сети Хопфилда

Сети Хопфилда отличаются от ранее рассмотренных типов нейронных сетей следующими существенными признаками:

- наличие обратных связей, идущих с выходов сетей на их входы по принципу «со всех на все»;
- расчет весовых коэффициентов нейронов проводится на основе исходной информации лишь перед началом функционирования сети, и все обучение сети сводится именно к этому расчету без обучающих итераций;
- при предъявлении входного вектора сеть «сходится» к одному из запомненных в сети эталонов, представляющих множество равновесных точек, которые являются локальными минимумами функции энергии, содержащей в себе всю структуру взаимосвязей в сети.

Проблема устойчивости сети Хопфилда была решена после того, как Кохеном и Гроссбергом была доказана теорема, определяющая достаточное условие устойчивости сетей с обратными связями, а именно, сеть с обратными связями является устойчивой, если матрица ее весов симметрична ($w_{ij} = w_{ji}$) и имеет нули на главной диагонали ($w_{ii} = 0$).

Динамическое изменение состояний сети может быть выполнено, по крайней мере, двумя способами: синхронно и асинхронно. В первом случае все элементы модифицируются одновременно на каждом временном шаге, во втором – в каждый момент времени выбирается и подвергается обработке один элемент. Этот элемент может выбираться случайно.

Рассмотрим синхронную бинарную сеть Хопфилда, представляющую собой пример сети с *дискретными состояниями и дискретным временем*, и сформулируем решаемую ею задачу следующим образом.

В качестве нейронов сети рассмотрим нейроны с пороговой функцией активации, выходы которых принимают значение либо «0», либо «1» при превышении взвешенной суммой значений входов некоторого порогового уровня.

Предварительно в сети матрицей весовых коэффициентов задан набор эталонов. Каждый эталон при этом является точкой из конечного множества равновесных точек, характеризующих минимум энергии сети (функции Ляпунова):

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} y_i y_j - \sum_{j=1}^n x_j y_j + \sum_{j=1}^n \theta_j y_j, \quad (3.1)$$

где E – искусственная энергия сети; w_{ij} – вес от выхода i -го ко входу j -го нейрона; x_j, y_j – вход и выход j -го нейрона; θ – порог j -го нейрона.

Главное свойство энергетической функции состоит в том, что в процессе эволюции состояний нейронной сети согласно уравнению она уменьшается и достигает локального минимума (аттрактора), в котором сохраняет постоянную энергию. Это позволяет решать задачи комбинаторной оптимизации, если они могут быть сформулированы как задачи минимизации энергии.

Обозначим вектор, описывающий k -й эталон, через $X^k = \{x_i^k\}$, $k = 1, \dots, K$, K – число эталонов. На вход сети подается произвольный вектор $X = \{x_i\}$.

В результате серии итераций сеть должна выделить эталон, соответствующий входному вектору, или дать заключение о том, что входные данные не соответствуют ни одному из эталонов.

После отдельной итерации общее изменение энергии сети, вызванное изменением состояний всех нейронов, составит:

$$\Delta E = - \sum_{j=1}^n \left[\sum_{i \neq j} (w_{ij} y_i) + x_j - \theta_j \right] \Delta y_j, \quad (3.2)$$

где Δy_j – изменение выхода j -го нейрона после итерации.

Анализ выражения (3.2) показывает, что любое изменение состояния нейронов либо уменьшит значение E , либо оставит его без изменения. Второй случай указывает на достижение сетью устойчивого состояния и выделение эталона, наилучшим образом сочетающегося с входным вектором.

При распознании входного вектора (частично представленного или искаженного) выходы сети будут содержать соответствующий эталон, т.е. $Y = X^k$, где $Y = \{y_i\}$ – выходной вектор. В противном случае выходной вектор не совпадает ни с одним эталоном.

Для безошибочной работы сети Хопфилда число запоминаемых эталонов n не должно превышать 0,15 n .

Кроме того, в случае высокой степени корреляции нескольких эталонов возможно возникновение перекрестных ассоциаций при их предъявлении на входах сети. Требование достаточного (но не необходимого) усло-

вия слабой коррелируемости образов можно представить как выполнение следующего неравенства:

$$\sum_{k \neq j}^N |(x^k, x^j)| < n, j = 1 \dots n \quad (3.3)$$

или в виде более сильного условия:

$$|(x^k, x^j)| < \frac{n}{N}, k = 1 \dots n, k \neq j. \quad (3.4)$$

Нейронные сети Хопфилда с *непрерывными состояниями* отличаются от вышерассмотренной сети непрерывной активационной функцией нейронов, в качестве которой наиболее часто выбирают сигмоидальную или логистическую функцию. Концептуально вопросы организации и функционирования этих сетей схожи.

Недостатком классического варианта сетей Хопфилда является их тенденция к стабилизации в локальных, а не в глобальных минимумах сети. Предложены *статистические сети Хопфилда*, в которых этот недостаток преодолевается за счет задания статистических, а не детерминистских правил изменения состояний нейронов.

С этой целью для каждого j -го нейрона вводится вероятность изменения его состояния ρ_j как функция от величины, на которую выход нейрона s_j превышает его порог (для бинарной сети Хопфилда):

$$\rho_j = \frac{1}{1 + \exp\left(-\frac{\Delta E_j}{\phi}\right)}, \quad (3.5)$$

где $\Delta E_j = s_j - \theta_j$, ϕ – параметр, изменяемый в процессе стабилизации сети. Тогда после начального задания весовых коэффициентов нейронов процедура поиска минимума энергии сети для установленного входного вектора выглядит следующим образом.

ШАГ 1. Задать большое значение параметра ϕ .

ШАГ 2. Установить на выходе j -го нейрона значение «1» с вероятностью ρ_j и значение «0» с вероятностью $1 - \rho_j$.

ШАГ 3. Постепенно уменьшать значение параметра ϕ , пока не будет достигнуто равновесие.

Нейронные сети Хэмминга

В случае, если необходимо определить номер эталона, ближайший к предъявленному входному вектору, может быть использована сеть Хемминга. Преимуществами этой сети являются меньшие затраты на память и объем вычислений.

Нейронная сеть Хэмминга (рис. 3.4) состоит из входного, скрытого и выходного слоев нейронов. Скрытый и выходной слои содержат по K нейронов, где K – число эталонов. Нейроны скрытого слоя n синапсами соединены с выходами нейронов входного слоя сети. Выходы нейронов выходного слоя связаны со входами остальных нейронов этого слоя отрицательными обратными (ингибиторными) связями. Единственная положительная обратная связь подается с выхода для каждого нейрона выходного слоя на его вход.

Сеть выбирает эталон с минимальным хэмминговым расстоянием от предъявленного входного вектора путем активизации только одного выхода сети (нейрона выходного слоя), соответствующего этому эталону.

Хэммингово расстояние представляет собой пример меры сходства или, вернее, различия, первоначально введенной для бинарных функций в диадном пространстве. Она применима для сравнения любых упорядоченных наборов, принимающих дискретные значения и, вероятно, является наилучшей из известных мер сходства между цифровыми кодами. Для бинарных последовательностей $x = (x_1, \dots, x_n)$ и $x' = (x'_1, \dots, x'_n)$ хэммингово расстояние можно определить следующим образом:

$$\rho(x, x') = bc\{(\bar{x}_i \wedge x'_i) \vee (x_i \wedge \bar{x}'_i) \mid i = 1 \dots n\}. \quad (3.6)$$

Функция $bc\{\bullet\}$ в данном случае определяется как число элементов набора $\{\bullet\}$, принимающих значение логической «1».

На этапе настройки сети Хэмминга устанавливаются следующие значения весов нейронов скрытого слоя и порога их активационной функции:

$$w_{ik} = \frac{x_i^k}{2}, \theta_k = n/2, \quad (3.7)$$

где x_i^k – i -й компонент k -го эталона, $i = 1 \dots n$, $k = 1 \dots K$. Коэффициенты отрицательных обратных связей нейронов выходного слоя задают равными

некоторой величине из интервала $0 < \varepsilon < 1/K$, коэффициенты положительной обратной связи равны +1.

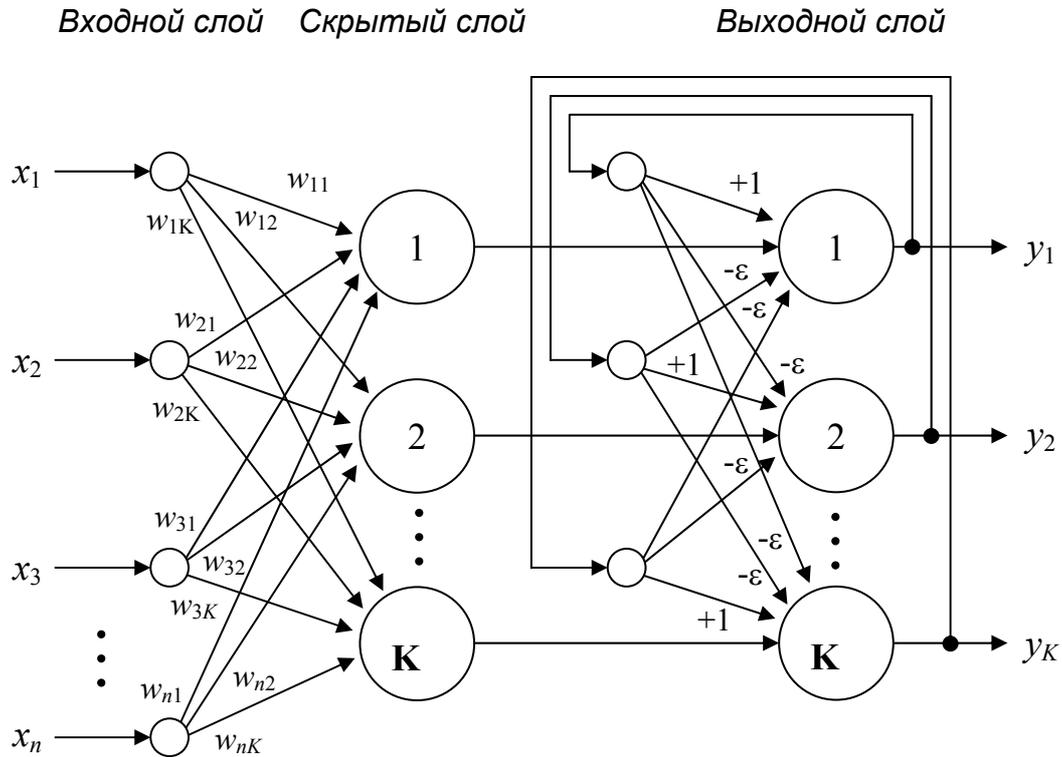


Рис. 3.4. Структура нейронной сети Хэмминга

Рассмотрим алгоритм функционирования сети Хэмминга.

ШАГ 1. На нейроны входного слоя подается вектор $X = \{x_i\}$, $i = 1 \dots n$. На их выходах формируются следующие значения (верхний индекс указывает номер слоя):

$$y_k^{(1)} = s_k^{(1)} = \sum_{i=1}^n w_{ik} x_i + \theta_j, k = 1 \dots K. \quad (3.8)$$

В соответствии с этим устанавливаются значения на выходах нейронов выходного слоя:

$$y_k^{(2)} = y_k^{(1)}, k = 1 \dots K. \quad (3.9)$$

ШАГ 2. В результате новой $(t+1)$ -й итерации определяются новые состояния нейронов выходного слоя:

$$S_k^{(2)}(t+1) = y_k^{(2)}(t) - \varepsilon \sum_{j=1, j \neq k}^n y_j^{(2)}(t), k = 1 \dots K, \quad (3.10)$$

$$y_k^{(2)}(t+1) = f[S_k^{(2)}(t+1)], k = 1 \dots K.$$

Активационная функция f имеет вид порога, причем величина «ступеньки» должна быть достаточно большой, чтобы возможные значения $S_k^{(2)}$ не приводили к насыщению.

ШАГ 3. Проверка изменения состояний нейронов выходного слоя за последнюю итерацию. Переход к шагу 2 в случае, если наблюдались изменения, иначе – окончание процедуры.

Роль нейронов входного слоя весьма условна: воспользовавшись один раз на шаге 1 значениями его весовых коэффициентов, сеть больше не обращается к нему, поэтому этот слой может быть вообще исключен из сети (заменен на матрицу весовых коэффициентов).

В заключение можно сделать следующее обобщение. Сети Хопфилда и Хэмминга позволяют просто и эффективно решить задачу автоассоциативной памяти: воссоздание образов по неполной и искаженной информации. Невысокая емкость сетей (число запоминаемых образов) объясняется тем, что сети не просто запоминают образы, а позволяют проводить их обобщение, например, с помощью сети Хэмминга возможна классификация по критерию максимального правдоподобия. Вместе с тем легкость построения программных и аппаратных моделей делает эти сети привлекательными для многих практических применений.

В случае, если необходимо определить эталон, ближайший к предъявленному входному вектору (например на основе хэммингова расстояния), часто возникают проблемы, связанные с различием длин или с ограничениями на длину последовательностей или количеством компонентов в наборах.

Отметим один важный аспект проблемы сравнения векторов различной длины. Так, последовательность большей длины может представлять собой функцию в пространстве с числом измерений большим, чем число измерений другой функции на разницу числа параметров в длинах последовательностей. Это определяет возможность перехода к оценке не только количественного, но и качественного сходства векторов, к оперированию в терминах вероятности, нечетких оценок отнесению вектора к какому-либо классу.

Эти различия и ограничения сравнения векторов различной длины можно устранить различными способами, например с помощью меры сходства Танимото.

Контрольные вопросы и задания

1. В чем заключается суть явления абсолютной рефрактерности и постактивационного усиления?
2. Какова роль глиальных клеток в решении задачи хранения информации?
3. Опишите процесс запоминания информации в биологических нейронных сетях.
4. Как формируются следы памяти?
5. Как называется способ доступа к информации, базирующийся на ассоциации? Перечислите преимущества ассоциативного доступа к информации.
6. Охарактеризуйте механизм долговременной биологической памяти.
7. Назовите и поясните способы формирования ассоциаций.
8. Дайте определение модели ассоциативной памяти.
9. Изобразите структурную схему модели ассоциативной памяти с обратной связью.
10. Изобразите и охарактеризуйте структуру нейронной сети Хопфилда.
11. Сформулируйте суть проблемы устойчивости сети Хопфилда. Назовите основные методы решения этой проблемы.
12. Дайте определение бинарной сети Хопфилда с дискретными состояниями и дискретным временем. В чем отличие этой сети от сети с непрерывными состояниями?
13. Опишите основные этапы процедуры обучения сети Хопфилда.
14. Приведите структурную схему и алгоритм функционирования сети Хэмминга. Какой вид имеет активационная функция этой сети?
15. Назовите возможные способы применения сетей Хопфилда и Хэмминга для решения задачи реализации автоассоциативной памяти.

Глава 4. ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ

4.1. Нейрокомпьютерная система идентификации личности

В этом пункте предлагается возможный вариант построения программного обеспечения нейрокомпьютерной системы установления личности человека по прижизненным фотографиям (возможно, искаженным). Предлагаемое программное обеспечение может быть использовано для создания приборов идентификации личности (в мобильном или стационарном вариантах), применяемых в оперативной деятельности правоохранительных органов, в пунктах обязательной проверки личности на таможнях и в аэропортах, в территориальных бюро судебно-медицинской экспертизы.

Алгоритм идентификации человека по искаженной фотографии. Эталонные фотографии преобразуются в n -мерные бинарные векторы $X = (x_1, x_2, \dots, x_n)$, $x_i \in \{0, 1\}$, $i=1, 2, \dots, n$ и записываются в распределенную ассоциативную память, в качестве которой используется модель многослойной нейронной сети. Идентификация фотографии сводится к процедуре помехоустойчивой выборки информации из распределенной ассоциативной нейронной памяти.

Задача ассоциативной выборки информации может быть сформулирована следующим образом. Пусть задано конечное множество пар вида $\{X_k, Y_k\}$, $k \in S = \{1, 2, \dots, N\}$. Необходимо определить такую матрицу M , чтобы для всех $k \in S$ выполнялось условие

$$Y_k = M X_k. \quad (4.1)$$

Можно показать, что если все векторы линейно независимы, то существует единственное решение уравнения (4.1), причем матрица M определяется по формуле

$$M = Y(X^T X)^{-1} X^T, \quad (4.2)$$

где $X = [X_1, \dots, X_n]$, $Y = [Y_1, \dots, Y_n]$ – матрицы, составленные из векторов-столбцов X_k и Y_k ; T – операция транспонирования матрицы. Если векторы

X_k линейно зависимы, то существует единственное приближенное решение

$$M^T = YX^+, \quad (4.3)$$

где X^+ – матрица, псевдообратная матрице X . Теоретически матрица M существует, когда число пар $\{X_k, Y_k\}$ бесконечно. В этом случае она определяет структуру «бесконечной» памяти, понимаемой в смысле (4.1).

Рассмотрим случай ассоциативной выборки, реализуемый посредством оптимального линейного преобразования, когда входной и выходной образы тождественны, т.е. $Y_k = X_k \in R^n$.

Известно, что произвольный вектор $X_k \in R^n$ можно однозначно представить в виде суммы двух векторов

$$X = X^\wedge + X^\perp, \quad (4.4)$$

из которых X^\wedge представляет собой линейную комбинацию X_k ; X^\perp – остаточный вектор, ортогональный пространству $\mathfrak{Z} \subset \mathfrak{R}^n$. В частности, X^\wedge является ортогональной проекцией X на пространство \mathfrak{Z} . Вектор X является наилучшей линейной комбинацией векторов X_k , аппроксимирующей X на основе критерия наименьших квадратов. Обозначим

$$X^\wedge = \sum_{k=1}^N Y_k X_k, \quad (4.5)$$

где Y_k – скалярные множители, представляющие собой линейные регрессионные коэффициенты X относительно X_k . Отсюда видно, что X_k можно рассматривать как представления N различных записанных в распределенной памяти элементов или эталонных образов. Вектор X является (возможно, неполным) ключевым образом, с помощью которого информация ассоциативно выбирается из памяти. Если ключ X обнаруживает близкую корреляцию с одним из записанных в памяти образов, например X_r , то член $Y_r X_r$ будет в сумме (4.5) доминирующим. Это означает, что X_r является одним из эталонных образов, записанных в памяти. Остальные элементы в линейной комбинации X представляют собой искажение ключевого образа или шум, структура которого зависит от перекрестных корреляций, возникающих от других записанных в памяти образов.

В качестве вычислительной процедуры для расчета ортогональных проекций используется метод Грама-Шмидта. Построим ортогональный векторный базис для линейного пространства \mathfrak{R}^n . Предположим, что пер-

вым базисным вектором является $H_1=X_1$. Если X_2 не совпадает по направлению с X_1 , то очевидно, что вектор

$$H_2 = X_2 - \frac{(X_2, H_1)}{\|H_1\|^2} H_1, \quad (4.6)$$

где (X_2, H_1) – скалярное произведение векторов X_2 и H_1 ; $\|H_1\|$ – евклидова норма вектора H_1 , ортогональна вектору $H_1=X_1$. Следовательно, H_2 можно выбрать в качестве второго базисного вектора новой системы векторов. В случае совпадения по направлению векторов X_1 и X_2 вектор X_2 представляется вектором X_1 и тем самым будет игнорироваться.

Далее определим последовательность векторов $\{H_i\}$, в которой каждый новый вектор вычисляется в соответствии с рекуррентным соотношением

$$H_i = X_i - \sum_{j=1}^{i-1} \frac{(X_i, H_j)}{\|H_j\|^2} H_j, \quad (i=1, 2, \dots, N), \quad (4.7)$$

где сумма по j включает только члены с ненулевыми векторами H_j . Можно показать, что все H_i ортогональны между собой. Допустим, что векторы H_1, H_2, \dots, H_{i-1} взаимно ортогональны; это означает, что для всех $q \leq i$ и ненулевых H_q, H_j имеет место равенство

$$(H_j, H_q) = \|H_j\| \cdot \|H_q\| \cdot \delta_{jq}, \quad (4.8)$$

где δ_{jq} – символ Кронекера ($\delta_{jq}=1$, при $j=q$; $\delta_{jq}=0$ при $j \neq q$). Подстановка дает

$$(H_j, H_q) = \begin{cases} (X_i, H_q) - (X_i, X_q) = 0, & H_q = 0, \\ (X_i, H_q) = 0, & H_q = 0. \end{cases} \quad (4.9)$$

Таким образом, соотношение (4.7) справедливо также и для вектора H_i , а следовательно, и для всех векторов.

Разложение ключевого вектора $X = X^\wedge + X^\perp$ на проекции X^\wedge и X^\perp можно получить путем продолжения указанного выше рекуррентного процесса на один шаг дальше

$$X^\perp = H_{N+1}, \quad X^\wedge = X - H_{N+1}. \quad (4.10)$$

Алгоритм краниофациальной идентификации личности. Пусть даны точки $P_i(x_i, y_i, z_i)_{i=1..n}$, $P_i'(x_i', y_i', z_i')_{i=1..n}$ в правоориентированной системе координат декартова пространства \mathfrak{R}^3 , где $z_i|_{i=1..n}$, $z_i'|_{i=1..n}$ – неизвестны;

n – общее число точек, применяемых при краниофациальной идентификации. Рассмотрим преобразование координат в трехмерном пространстве

$$\begin{aligned} x_i &= \cos\beta\cos\gamma S_x x_i' + (\sin\alpha\sin\beta\cos\gamma - \cos\alpha\sin\gamma) S_y y_i' + \\ &+ (\cos\alpha\sin\beta\cos\gamma + \sin\alpha\sin\gamma) S_z z_i' + x_0; \\ y_i &= \cos\beta\sin\gamma S_x x_i' + (\sin\alpha\sin\beta\sin\gamma + \cos\alpha\cos\gamma) S_y y_i' + \\ &+ (\cos\alpha\sin\beta\sin\gamma - \sin\alpha\cos\gamma) S_z z_i' + y_0; \\ z_i &= -\sin\beta S_x x_i' + \sin\alpha\cos\beta S_y y_i' + \cos\alpha\cos\beta S_z z_i' + z_0, \end{aligned} \quad (4.11)$$

где $i=1, \dots, n$; S_x, S_y, S_z – операторы масштабирования; α, β, γ – углы вращения соответственно вокруг осей абсцисс, ординат, аппликат.

Предположим, что $S_x = S_y = S_z = S$. Тогда систему (4.11) можно привести к виду

$$\begin{aligned} x_i - (\cos\beta\cos\gamma x_i' + (\sin\alpha\sin\beta\cos\gamma - \cos\alpha\sin\gamma) y_i' + \\ + (\cos\alpha\sin\beta\cos\gamma + \sin\alpha\sin\gamma) z_i') S - x_0 &= 0; \\ y_i - (\cos\beta\sin\gamma x_i' + (\sin\alpha\sin\beta\sin\gamma + \cos\alpha\cos\gamma) y_i' + \\ + (\cos\alpha\sin\beta\sin\gamma - \sin\alpha\cos\gamma) z_i') S - y_0 &= 0; \\ z_i - (-\sin\beta x_i' + \sin\alpha\cos\beta y_i' + \cos\alpha\cos\beta z_i') S - z_0 &= 0. \end{aligned} \quad (4.12)$$

Все неизвестные, входящие в систему уравнений (4.12), можно представить в виде вектора

$$\vec{v} = (z_i, z_i', x_0, y_0, z_0, S, \alpha, \beta, \gamma) |_{i=1 \dots n}, \quad (4.13)$$

где z_i, z_i' – координаты; (x_0, y_0, z_0) – вектор переноса. Полученная система уравнений имеет $4n+7$ неизвестных и зависит от $4n$ параметров x_i, x_i', y_i, y_i' .

Если параметры x_i, x_i', y_i, y_i' принимают значения, такие что существует вектор неизвестных (4.13), при подстановке которого в систему уравнений (4.12) она превращается в тождество, то делается вывод о совпадении фотографий.

Следует отметить, что преобразование (4.11) является аффинным в евклидовом пространстве \mathbb{R}^3 . Для доказательства этого утверждения достаточно определить квадрат расстояния между произвольными точками P_i, P_k и P_i', P_k' , используя преобразование (4.12)

$$(x_i - x_k)^2 + (y_i - y_k)^2 + (z_i - z_k)^2 = [(x_i' - x_k') + (y_i' - y_k') + (z_i' - z_k')] S^2. \quad (4.14)$$

Из соотношения (4.14) следует, что расстояние между точками инвариантно при преобразованиях вида (4.12). Так как равенство (4.14) выполняется для произвольных пар точек, то преобразование (4.12) сохраняет отношение длин отрезков, т.е. является аффинным в евклидовом пространстве \mathfrak{R}^3 .

Идентификация личности производится оператором (экспертом) путем установки точек в конкретный участок фотографии, при этом имеют место субъективная составляющая и соответствующий доверительный интервал. Поэтому не требуется решать данную задачу точно, достаточно минимизировать отклонение образа точек $P'(x_i', y_i', z_i')|_{i=1...n}$ от точек $P(x_i, y_i, z_i)|_{i=1...n}$. Процедура минимизации отклонений заключается в определении вектора неизвестных параметров (4.13), минимизирующего три группы невязок:

$$\begin{aligned} \delta_1 &= x_i - (\cos\beta\cos\gamma x_i' + (\sin\alpha\sin\beta\cos\gamma - \cos\alpha\sin\gamma)y_i' + \\ &+ (\cos\alpha\sin\beta\cos\gamma + \sin\alpha\sin\gamma)z_i') S - x_0; \\ \delta_2 &= y_i - (\cos\beta\sin\gamma x_i' + (\sin\alpha\sin\beta\sin\gamma + \cos\alpha\cos\gamma)y_i' + \\ &+ (\cos\alpha\sin\beta\sin\gamma - \sin\alpha\cos\gamma)z_i') S - y_0; \\ \delta_3 &= z_i - (-\sin\beta x_i' + \sin\alpha\cos\beta y_i' + \cos\alpha\cos\beta z_i') S - z_0. \end{aligned} \quad (4.15)$$

Введем обозначения: $f_i (i=1 \dots 3n)$ – невязки (4.15); $k=2n+7$; $\Phi: \mathfrak{R}^3 \rightarrow \mathfrak{R}^1$, где функция Φ определяется следующим образом

$$\begin{aligned} \Phi(z_i, z_i', x_0, y_0, z_0, S, \alpha, \beta, \gamma) &= \sum_{i=1}^n b_{3i-2} (x_i - (\cos\beta\cos\gamma x_i' + (\sin\alpha\sin\beta\cos\gamma - \\ &- \cos\alpha\sin\gamma)y_i' + (\cos\alpha\sin\beta\cos\gamma + \sin\alpha\sin\gamma)z_i') S - x_0)^2 + \\ &+ b_{3i-1} (y_i - (\cos\beta\sin\gamma x_i' + (\sin\alpha\sin\beta\sin\gamma + \cos\alpha\cos\gamma)y_i' + \\ &+ (\cos\alpha\sin\beta\sin\gamma - \sin\alpha\cos\gamma)z_i') S - y_0)^2 + b_{3i-1} (z_i - \\ &- (-\sin\beta x_i' + \sin\alpha\cos\beta y_i' + \cos\alpha\cos\beta z_i') S - z_0)^2 \end{aligned}$$

или, учитывая введенные обозначения:

$$\Phi(\vec{v}) = \sum_{j=1}^{3n} b_j (f_j(\vec{v}))^2. \quad (4.16)$$

Таким образом, задача краниофациальной идентификации сводится к задаче нелинейной оптимизации вида

$$\Phi(\vec{v}) \rightarrow \min. \quad (4.17)$$

Будем считать, что ошибки эксперта ε_j ($j=1, \dots, 3n$) при установке точек (определении координат (x_i, y_i) и (x_i', y_i')) не имеет систематической составляющей, т.е. ошибок, повторяющихся при всех наблюдениях и обычно являющихся следствием дефекта измерительной аппаратуры или методики измерений, и распределены нормально с нулевым математическим ожиданием ($M\varepsilon_j=0$). Весовые коэффициенты b_j ($j=1, \dots, 3n$) учитывают различную точность позиционирования точек (в частности, если измерения являются равноточными, можно положить $b_j=1$ ($j=1, \dots, 3n$)). Иными словами, весовые коэффициенты должны учитывать то, что некоторые установленные точки менее надежны, чем другие, и следует стремиться к тому, чтобы оценки параметров \vec{v} подвергались меньшему влиянию этих измерений по сравнению с более точными измерениями.

Для каждой точки можно определить интервал неопределенности (доверительный интервал) при ее позиционировании, который может быть выбран экспертом. В частности, если возникают какие-либо затруднения при установке точки, доверительный интервал должен быть увеличен по сравнению с другими, более надежно установленными точками. Заметим, что понятие доверительного интервала здесь не рассматривается в строго математическом смысле.

Пусть ξ_i – радиус области неопределенности при определении координат реперных точек (x_i, y_i) и (x_i', y_i') , $i=1, \dots, n$. Из математической статистики известно, что величины ξ_i следует рассматривать как среднеквадратическое отклонение σ_j при определении значений величин отклонений f_j . Измерения с различной точностью должны вносить одинаковый вклад в целевую функцию (4.16). Чтобы обеспечить выполнение этого условия, необходимо выбрать весовые коэффициенты b_j таким образом, чтобы величина $b_j f_j^2$ имела одинаковую дисперсию для всех слагаемых в целевой функции (4.16), т.е. положить

$$b_j = \frac{r^2}{\sigma_j^2}, \quad (4.18)$$

где r – произвольный коэффициент.

Выберем r таким образом, чтобы значение целевой функции (4.16) в точке минимума имело смысл суммарного отклонения

образа точек $P'(x_i', y_i', z_i')|_{i=1..n}$ от точек $P(x_i, y_i, z_i)|_{i=1..n}$. Для этого коэффициент r следует вычислять по формуле

$$r = \frac{1}{3n} \sum_{l=1}^n \sigma_l = \frac{1}{n} \sum_{l=1}^n \xi_l,$$

т.е. r выбирается равным среднему арифметическому от величин σ_j (среднему интервалу неопределенности в установке реперных точек). В результате получаем следующую формулу для весовых коэффициентов $b_j=1$ ($j=1, \dots, 3n$):

$$b_{3i-2} = b_{3i-1} = b_{3i} = \frac{\frac{1}{n} \sum_{l=1}^n \xi_l}{\xi_l}, \quad I=1, \dots, n. \quad (4.19)$$

Для равноточных измерений выполняется условие $\xi_1 = \xi_2 = \dots = \xi_n$, поэтому все весовые коэффициенты будут равны единице. Так как величина $\frac{1}{n} \sum_{l=1}^n \xi_l$ в формуле (4.19) является средним интервалом неопределенности при установке реперных точек, то если при некоторых i величина

$$\xi_i > \frac{1}{n} \sum_{l=1}^n \xi_l \quad (4.20)$$

(т.е. при установке i -й точки возникают затруднения), то соответствующие этой точке весовые коэффициенты $b_{3i-2} = b_{3i-1} = b_{3i}$ будут меньше единицы и, соответственно, будут вносить меньший вклад в целевую функцию.

Математическим результатом расчета является значение целевой функции $\Phi(\vec{v})$ в точке минимума \vec{v}^* . Однако использование этого значения в качестве критерия для анализа степени совпадения фотографий неудобно вследствие различного количества n используемых точек на разных фотографиях (т.е. в формуле (4.16) будет различное количество слагаемых). Поэтому в качестве критерия степени совпадения фотографий следует выбрать значение

$$\Delta = \frac{\Phi(\vec{v}^*)}{3n}. \quad (4.21)$$

Величина Δ имеет смысл среднего отклонения образа точек $P_i'(x_i', y_i', z_i')|_{i=1..n}$ от точек $P_i(x_i, y_i, z_i)|_{i=1..n}$, взятого последовательно по всем соответствующим координатам этих точек. Значение такого критерия не зависит от числа используемых реперных точек, что позволяет использовать его для последовательного сравнения одной фотографии с рядом других фотографий.

Программное обеспечение. Алгоритмы идентификации личности человека по фотографии реализованы в виде пакета прикладных программ (ППП), позволяющего выполнять последовательные сравнения исследуемой фотографии с записанными в памяти эталонными фотографиями. Входная информация для ППП представлена в виде графических файлов формата Windows BMP, в который должны быть преобразованы изображения, полученные с помощью сканера либо цифровой видеокамеры. ППП реализован средствами системы визуального программирования Borland Delphi 5 и работает под управлением операционных систем Windows 95/98/2000 и Windows NT 4.0. Распределенная ассоциативная память, в которой хранятся преобразованные эталонные фотографии, представлена в виде программной имитационной модели многослойной нейронной сети. Задача нелинейной оптимизации решается в двух режимах: с помощью алгоритма Дэвидона–Флетчера–Пауэлла для минимизации целевой функции (4.16) с оптимизацией по направлению методом кубической интерполяции; на основе применения обученной двухслойной нейронной сети без обратных связей.

На рис. 4.1 приведен интерфейс приложения идентификации человека в условиях искажения ключевого образа (исследуемой фотографии).

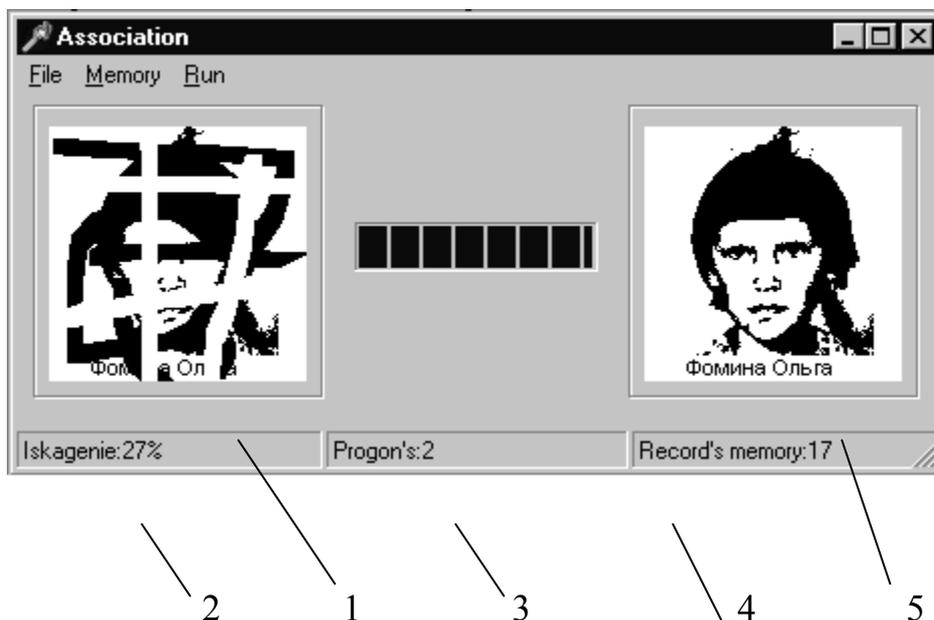


Рис. 4.1. Интерфейс приложения идентификации человека в условиях искажения исследуемой фотографии

Интерфейсные элементы обозначены цифрами и имеют следующий смысл: 1 – окно с ключевым образом (исследуемой фотографией);

2, 3, 4 – информационные поля, содержащие соответственно коэффициент искажения в процентах от эталонного образа, число итераций, количество образов, записанных в распределенную ассоциативную память; 5 – окно с результатами идентификации.

В главном меню приложения реализованы команды, выполняющие следующие функции:

File/Open – загружает исследуемую фотографию;

Memory/View – просмотр содержимого памяти;

Memory/Append – добавляет новый образ в нейронную память (рис. 4.2);

Memory/Delete – удаляет образ из памяти;

Memory/File path – устанавливает путь к файлу, в котором регистрируются образы, хранимые в распределенной нейронной памяти (рис. 4.3).

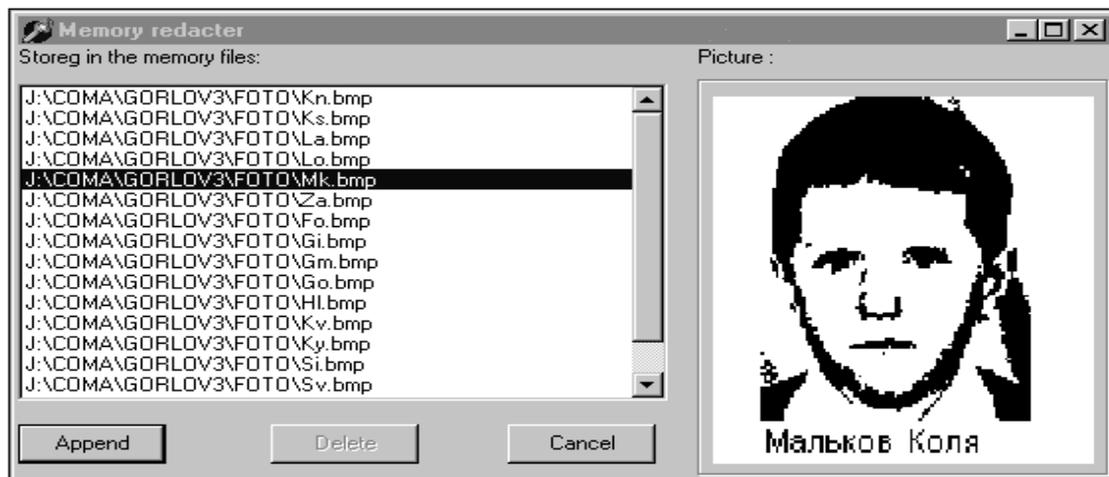


Рис. 4.2. Окно добавления (удаления) графических образов в распределенную нейронную память



Рис. 4.3. Окно установки пути к файлу регистрации образов

Интерфейс приложения краниофациальной идентификации человека приведен на рис. 4.4. Цифрами обозначены следующие интерфейсные элементы:

1 – окно с исследуемой фотографией; 2 – окно со справочником по реперным точкам (в режиме установки реперных точек) и с фотографией, выделенной в таблице 3 (в режиме отображения полученных результатов); 3 – таблица с координатами и номерами реперных точек в режиме установки реперных точек и с отсортированным списком фотографий в режиме отображения полученных результатов (в этой таблице при включенном переключателе 12 возможно выделение двойным щелчком мыши строк с именами графических файлов с фотографиями для повторного расчета); 4 – кнопка добавления новой реперной точки; 5 – кнопка удаления выделенной в табл/ 3 точки; 6 – кнопка очистки таблицы; 7 – кнопка открытия графического файла с исследуемой фотографией и файла с координатами реперных точек; 8 – кнопка сохранения координат реперных точек; 9 – кнопка начала сравнения исследуемой фотографии с эталонными фотографиями (переключает программу из режима установки реперных точек в режим отображения полученных результатов);

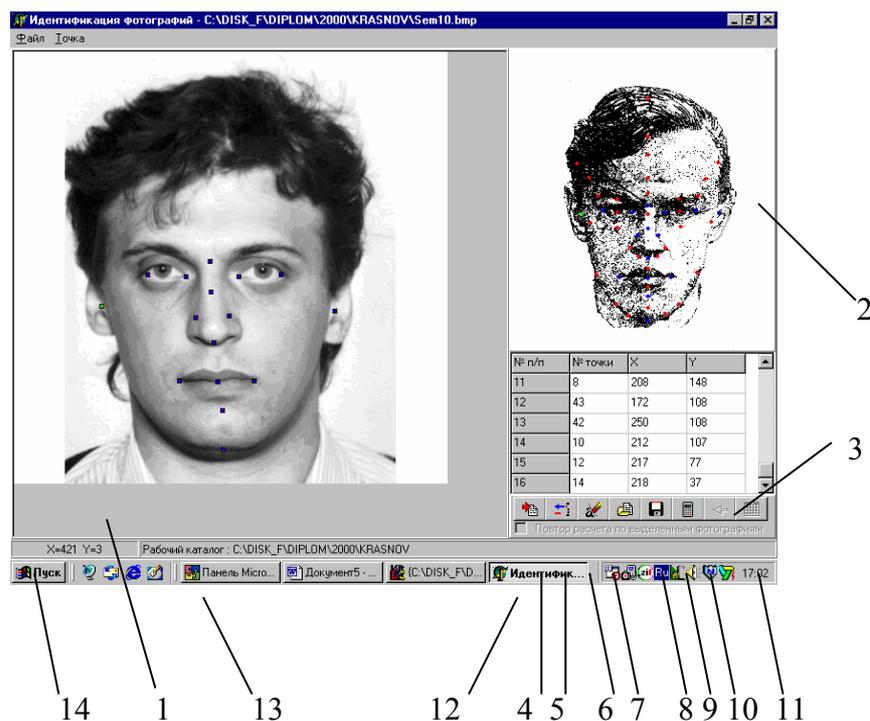


Рис. 4.4. Интерфейс приложения краниофациальной идентификации личности человека

10 – кнопка загрузки фотографии, выделенной в таблице 3 в окно 1 (активна в режиме отображения полученных результатов); 11 – кнопка показа

таблицы отклонений для исследуемой фотографии и выделенной в таблице 3 (активна в режиме отображения полученных результатов); 12 – переключатель для начала повторного расчета из выделенных в табл. 3 фотографий; 13 – текущий рабочий каталог, в котором расположены эталонные фотографии; 14 – координаты курсора мыши в системе координат исследуемой фотографии.

Кнопки 6, 7, 10, также щелчок на фотографии в окне 1 позволяют переходить из режима отображения полученных результатов в режим установки реперных точек. В главном меню доступны команды, дублирующие интерфейсные элементы 4 – 12, а также команды, выполняющие следующие функции:

1. Файл/Установить рабочий каталог – устанавливает каталог, в котором хранятся графические файлы с эталонными фотографиями и файлы с данными оцифровки фотографий.

2. Файл/Сохранить рабочий каталог – сохраняет рабочий каталог для его установки при следующей загрузке приложения.

3. Точка/Показывать – устанавливает режим отображения реперных точек в справочнике 2.

4. Точка/Параметры – устанавливает параметры используемого алгоритма нелинейной оптимизации и допустимые отклонения при установке реперных точек.

5. Точка/Сохранить – сохраняет параметры в конфигурационный файл.

Процесс установки реперных точек можно рассматривать как процесс оцифровки фотографии. Файл с данными о реперных точках головы имеет то же название, что и графический файл с фотографией и имеет расширение INT. Открытие графического файла с фотографией осуществляется нажатием кнопки 7. Если существует соответствующий графическому int-файл, то он также открывается и данные из него заносятся в табл. 3.

Для установки новой реперной точки необходимо выполнить следующие действия: 1) создать новую точку нажатием кнопки 4 (не требуется для первой точки); 2) определить номер реперной точки. Для этого нужно щелкнуть левой кнопкой мыши на справочнике реперных точек 2 в соответствующей точке, номер точки будет автоматически занесен в текущий

86

столбец табл. 3; 3) определить координаты реперной точки. Вычисление координат выполняется в результате установки курсора мыши в определенной точке фотографии, при этом координаты точки будут автоматически занесены в соответствующие столбцы табл. 3, а соответствующая точка на фотографии подсвечивается синим цветом. Можно указать координаты точки непосредственно в таблице 3. Координаты измеряются в пикселях относительно левого нижнего угла изображения. Результатом выполнения этих действий является создание новой строки в табл. 3 (рис. 4.5).

Изменить номер реперной точки можно, выделив нужную точку в табл. 3 и указав новую в справочнике реперных точек. Изменение координат реперной точки осуществляется «перетаскиванием» соответствующей точки в окне 1 с помощью мыши.

После установки всех реперных точек необходимо сохранить результаты оцифровки фотографий с помощью кнопки 8. В противном случае данная фотография при ее использовании в качестве эталонной не будет сравниваться с исследуемой фотографией.

Установка параметров и допустимых отклонений в позиционировании реперных точек осуществляется выбором пункта меню Точка/Параметры в окне, изображенном на рис. 4.6. Устанавливаются следующие параметры:

1. Допустимое отклонение в установке реперных точек (радиус области неопределенности ξ_i , $I=1, \dots, n$). Измеряется в пикселях и определяется экспертом на основе имеющегося исследуемого материала.

2. Максимальное число итераций в процедуре минимизации функции (алгоритм Дэвидона – Флетчера – Пауэлла, рекомендуемое значение от 500 до 1000).

3. Порог активизации нейронов в алгоритме ассоциативного поиска информации в распределенной нейронной памяти.

№ п/п	№ точки	X	Y
1	20	79	174
2	22	197	228
3	6	270	253
4	7	278	225
5	37	258	187
6	8	286	159



 Номер точки Координаты точек

Рис. 4.5. Установка реперных точек

Перед началом идентификации фотографии необходимо установить путь к каталогу, в котором хранятся эталонные фотографии. Это осуществляется выбором пункта меню Файл/Выбрать рабочий каталог. Результаты сравнения исследуемой фотографии с эталонными выводятся в окне, приведенном на рис. 4.5, в порядке возрастания критерия (4.20).

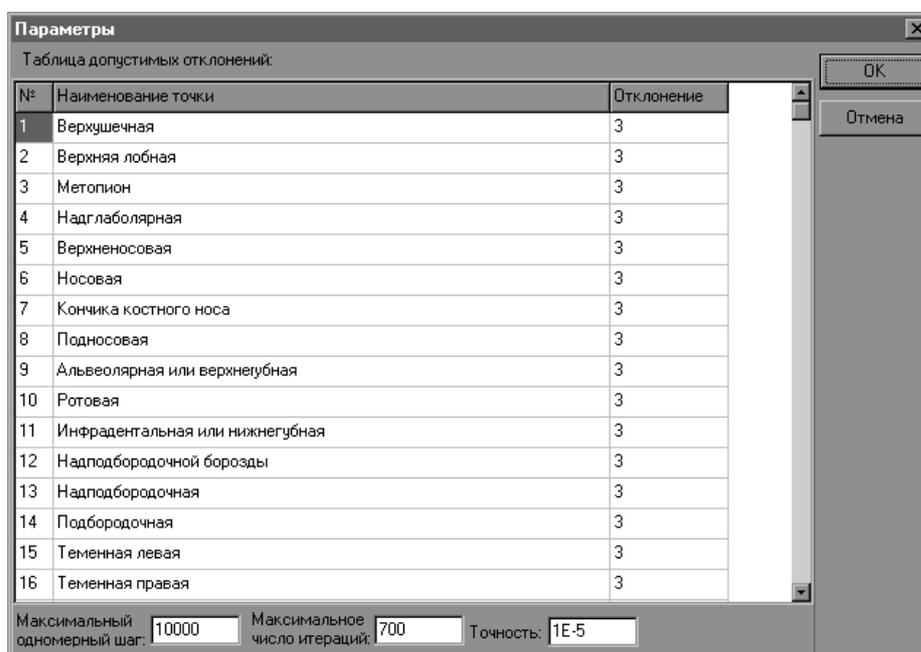


Рис. 4.6. Окно установки параметров

Для идентификации личности человека по фотографии эксперт должен выполнить следующие действия:

1. Загрузить исследуемую фотографию в окно 1 с помощью кнопки 3 и оцифровать ее, если этого не было сделано ранее.

2. Изменить, если это необходимо, установленные по умолчанию допустимые отклонения в позиционировании реперных точек и выполнить расчет нажатием кнопки 9. Результатом расчета, как уже было отмечено, является список эталонных фотографий, упорядоченный по возрастанию значения критерия (4.20). Если значение критерия для первой фотографии в полученном списке значительно меньше (в 3 – 4 раза) других значений, то эта эталонная фотография является результатом идентификации.

3. В случае получения неоднозначного результата можно выполнить повторный расчет. Для этого надо включить переключатель 12 и двойным

щелчком мыши выделить фотографии, по которым необходимо произвести повторный расчет. Выбор фотографий для повторного расчета производится на основе визуального анализа. Изменить, если необходимо, допустимые отклонения и параметры алгоритма. Начать повторный расчет нажатием кнопки 9.

4. Повторить пункт 3 необходимое число раз до получения однозначного результата.

При анализе правильности установки реперных точек и соответствующем изменении значений их координат и допустимых отклонений можно пользоваться таблицей отклонений по каждой используемой реперной точке для исследуемой фотографии. Таблица отклонений вызывается с помощью кнопки 11.

Результаты тестирования программного обеспечения. Тестирование компьютерной системы в режиме краниофациальной идентификации проводилось на реальном наборе данных, включающем 100 эталонных фотографий, среди которых были фотографии двух человек в различных ракурсах. Результатов, свидетельствующих о том, что рассчитанный минимум не является глобальным, получено не было. Качество идентификации исследуемой фотографии полностью зависит от правильности установки реперных точек. Рекомендованное количество используемых реперных точек – 12 – 18. В этом случае достигается хорошее качество идентификации при удовлетворительном времени расчета.

На рис. 4.7 приведены результаты тестирования программного обеспечения в режиме идентификации личности по искаженной фотографии. Пара изображений на рис. 4.7,а состоит из исследуемой фотографии (ключевого образа) и результата идентификации (результата выборки по ключу из ассоциативной памяти). В качестве ключевого образа использовалась одна из эталонных фотографий, на точки которой был наложен белый шум. Результатом идентификации является эталонная фотография, соответствующая ключевому образу. На рис. 4.7,б приведены результаты идентификации по ключевому образу, представляющему собой замаскированную эталонную фотографию. Приведенные результаты наглядно показывают эффективность разработанного программного обеспечения. Точная идентификация обеспечивается даже при искажении исследуемой фото-графии до 46 % от записанной в памяти эталонной фотографии. При увеличении количества хранимых в памяти фотографий

личении количества хранимых в памяти фотографий увеличивается время поиска изображения, но не уменьшается точность идентификации.

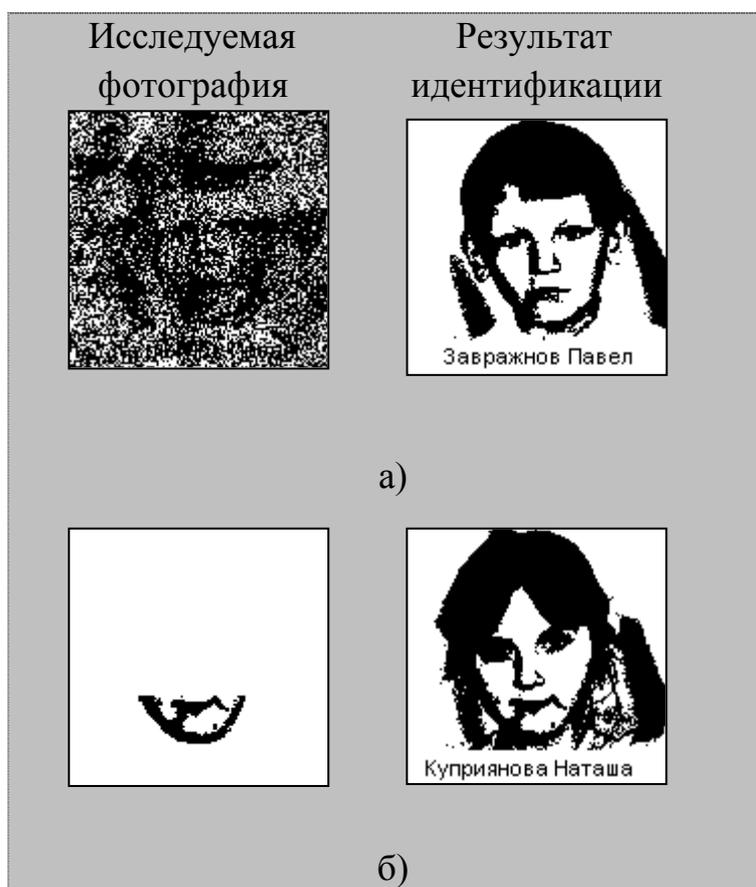


Рис. 4.7. Иллюстрация результатов идентификации личности по искаженной фотографии

4.2. Применение многослойных нейронных сетей к решению задачи защиты информации

Нейро-анатомические исследования послужили основой для создания моделей нейронных сетей как системы соединенных многочисленными связями простых процессорных элементов – нейронов. В зависимости от величины входного сигнала нейроны могут переходить из пассивного состояния (0 или -1) в активное состояние (1). Таким образом, состояние системы из N нейронов может быть задано двоичным кодом длины N , следовательно, всего возможно 2^N состояний

$$\vec{S} = (S_1, S_2, \dots, S_N), S_i = \pm 1. \quad (4.22)$$

Динамику системы нейронов можно рассматривать как движение в пространстве состояний. Для выделения близких состояний в этом пространстве можно ввести метрику – расстояние Хэмминга:

$$R_H = \frac{1 - \frac{1}{N} \sum_{i=1}^N S_i^\mu S_i^\nu}{2}, \quad (4.23)$$

где S^μ, S^ν – состояние сети; N – число нейронов.

Пространство состояний с определенной таким образом метрикой называется пространством Хэмминга, а динамика системы нейронов может быть описана как релаксация «возбужденного» состояния к одному из базовых (устойчивых) состояний, а именно к тому, до которого расстояние Хэмминга меньше.

Динамику системы определяют многочисленные межнейронные связи:

$$S_j(t+1) = \operatorname{sgn}\left(\sum_{j=1}^N w_{i,j} S_j\right) = \begin{cases} +1, & \text{if } \left(\sum_{j=1}^N w_{i,j} S_j\right) \geq 0, \\ -1, & \text{if } \left(\sum_{j=1}^N w_{i,j} S_j\right) < 0. \end{cases} \quad (4.24)$$

Многослойную нейронную сеть можно представить как универсальный декодер для последовательности M ключевых слов. Допустим, что требуется передать некоторое сообщение Φ (информационный массив, состоящий из нулей и единиц). До поступления на вход передающего устройства сообщение подвергается предварительной кодовой обработке с помощью многослойной нейронной сети. Алгоритм обработки входного сообщения состоит из следующих шагов.

Шаг 1. Информационный массив Φ разбивается на K -битовые фрагменты $\Phi_1, \Phi_2, \dots, \Phi_M$.

Шаг 2. Фрагмент Φ_i поступает на входной слой НС и передается на выходной слой, в результате чего i -й фрагмент преобразуется в $(K+d)$ -битовый код Φ_i^* .

Шаг 3. Запоминается состояние элементов выходного слоя сети (адреса элементов, которые переходят в активное состояние при передаче Φ_i).

По каналу связи передается информация о состоянии элементов выходного слоя НС (рис. 4.8). Получатель информации должен знать топологию и параметры нейронной сети. На приемном конце НС принимает двоичные коды фрагментов Φ_i^* ($i=1, 2, \dots, M$) и реализует обратное преобразование. Нейросетевой алгоритм предварительной кодовой обработки информации может быть реализован аппаратно в виде относительно недорогой микросхемы. Шифрование и дешифрование данных осуществляется в темпе поступления информации (On-Line). Алгоритм является симметричным в том смысле, что для кодирования и декодирования информации используется один и тот же ключ, роль которого выполняет нейронная сеть с определенными параметрами (в данном случае параметрами НС являются число элементов в слоях, число и конфигурация связей между слоями, число слоев).

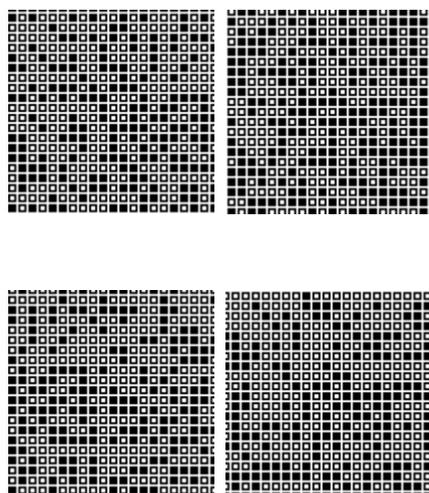


Рис. 4.8. Состояние элементов скрытых слоев нейронной сети (черным цветом выделены активные нейроны)

Задача конфиденциальной передачи по каналу связи информации о состоянии элементов нейронной сети может быть решена путем применения метода реконструкции динамических систем.

Возможность восстановления уравнения динамической системы (ДС) по ее одномерной реализации теоретически обоснована. Известно, что фазовый портрет аттрактора ДС можно восстановить по скалярному временному ряду $a_i = a(i\Delta t)$, если в качестве недостающих координат состояния использовать ряд a_i , взятый с некоторым запаздыванием.

Реконструкция динамической системы осуществляется по следующей схеме. На первом этапе выполняется расчет размерности пространства

вложения n . Затем задается общий вид математической модели и производится конкретизация эволюционных уравнений. Для реконструкции фазового портрета ДС по скалярному временному ряду может быть использован любой из известных способов.

Для восстановления фазового портрета воспользуемся методом последовательного дифференцирования исходного временного ряда. В этом случае математическая модель имеет вид

$$\frac{dx_1}{dt} = x_2, \quad \frac{dx_2}{dt} = x_3, \quad \dots, \quad \frac{dx_n}{dt} = f(x_1, x_2, \dots, x_n, \mu), \quad (4.25)$$

где f – нелинейная функция, которую необходимо определить; μ – вектор параметров.

Рассмотрим генератор динамического хаоса, математическая модель которого известна и имеет вид

$$\frac{dx}{dt} = F(x, \mu^0), \quad x \in R^n, \quad \mu^0 \in R^m, \quad (4.26)$$

где x – вектор состояния; F – вектор правых частей модельной системы; μ^0 – вектор постоянных значений параметров. Относительно медленная модуляция произвольного числа параметров информационными сигналами

$$\mu_i^* = \mu_i^0 + \mu_i(t) \quad (4.27)$$

позволяет реализовать одновременную передачу нескольких сообщений.

Передаваемый по каналу связи сигнал представляет собой одномерную реализацию колебательного процесса генератора хаоса и порождается неавтономной динамической системой вида

$$\begin{aligned} \frac{dx}{dt} &= F(x, \mu^0 + \mu(t)), \\ \mu^0 &= (\mu_1^0, \mu_2^0, \dots, \mu_m^0), \end{aligned} \quad (4.28)$$

$$\mu(t) = (\mu_1(t), \mu_2(t), \dots, \mu_m(t)).$$

Для решения задачи синтеза ДС по наблюдаемой одномерной реализации система (4.28) сводится к виду (4.25) путем замены переменных и преобразования правых частей таким образом, чтобы вместо вектор-функции F осталась только одна скалярная нелинейная функция f . С учетом предположения о том, что средняя скорость изменения параметров мала по сравнению с базовой частотой колебаний генератора (4.26), можно ввести в рассмотрение интервал времени t_0 , в течение которого значения параметров являются практически постоянными. Это обеспечивает возможность восстановления текущих значений параметров по коротким участ-

кам ее одномерной реализации, т.е. воспроизведения информационных сигналов $\mu_i(t)$, осуществляющих параметрическую модуляцию генератора хаоса.

Применение метода реконструкции к одномерной реализации $x_1(t)$ генератора хаоса, которую можно измерить на выходе передающего устройства, позволяет получателю информации, знающему общий вид математической модели (4.26), выделить полезные сигналы $\mu_i(t)$. Для этого необходимо n раз продифференцировать реализацию $x_1(t)$, что позволит определить левые части системы (4.25). В результате задача определения значений параметров в данный момент времени сводится к необходимости решения алгебраических уравнений с некоторым количеством неизвестных.

Следует заметить, что при компьютерной обработке используется не аналоговый сигнал, а дискретизованная временная зависимость $x_1(i\Delta t)$, поэтому производные определяются в дискретные моменты времени $i\Delta t$ по приближенным формулам численного дифференцирования. Записывая систему K алгебраических уравнений для L неизвестных ($K=[t_0/\Delta t]$, $L \ll K$) и решая ее методом наименьших квадратов, можно определить аппроксимацией неизвестные коэффициенты. Понятно, что чем меньше значение L , тем меньше ошибка аппроксимации, поэтому при практической реализации рассматриваемого метода защищенной передачи сообщений необходимо стремиться к максимально возможному упрощению модельной системы. Если ряд параметров системы (4.28) не меняется, целесообразно считать их заранее заданными и проводить аппроксимацию для меньшего числа неизвестных.

Для исследования работоспособности предлагаемого метода использовалась графическая информация. Передаваемое по каналу связи изображение представляется в виде бинарного вектора, разбивается на фрагменты и преобразуется с помощью нейронной сети.

В качестве генератора хаотических колебаний используется модель Ресслера. Считаем, что излучаемым сигналом генератора является одномерная реализация $y(t)$

$$\frac{dx}{dt} = -y - z, \quad \frac{dy}{dt} = x + ay, \quad \frac{dz}{dt} = b + z(x - c). \quad (4.29)$$

Путем замены переменных выполним преобразование (4.29) к виду (4.25). При этом получим следующий вид нелинейной функции f :

$$f = -b + (a - c)X - cY + (ac - 1)Z - aY^2 - aZ^2 - aXY + XZ + (a^2 + 1)YZ. \quad (4.30)$$

Предположим, что вектор $\mu = (a, b, c)$ содержит два неизвестных параметра b и c , которые модулируются информационными сигналами.

Тогда нелинейную функцию (4.30) можно представить в следующем виде:

$$f - aX + Z + aY^2 + aXY - XZ - (a^2 + 1)YZ = -b - c(X + Y - aZ). \quad (4.31)$$

Параметр b модулируется сигналом, несущим информацию о состоянии элементов выходного слоя НС. Модуляция параметра c позволяет передать информацию об очередности активизации элементов выходного слоя сети. Выберем в качестве закона изменения параметров b, c ступенчатую временную зависимость, подобную приведенной на рис. 4.9. Разобьем диапазон изменения каждого из параметров соответственно на 2^m и 2^n поддиапазонов, где $m \times m$ – размерность выходного слоя НС, n – число сегментов. Неизвестные величины b и c линейного алгебраического уравнения (4.31) определяются путем применения метода наименьших квадратов к результатам вычисления параметров в моменты времени $i\Delta t$ дискретизованного сигнала $y_i = y(i\Delta t)$ в пределах короткого времени t_0 .

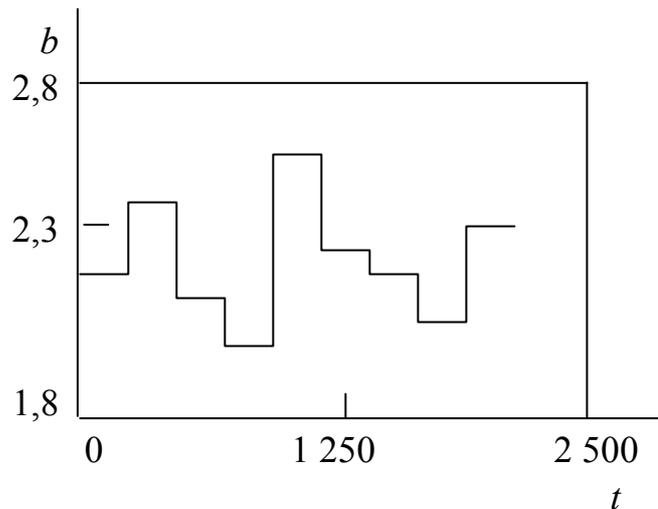


Рис. 4.9. Закон изменения параметра b системы Лоренца

На рис. 4.10 представлены исходное изображение (см. рис. 4.10,а), восстановленное с применением предложенного метода изображение (см. рис. 4.10,в), а также сигнал в канале связи (рис. 4.10,б).

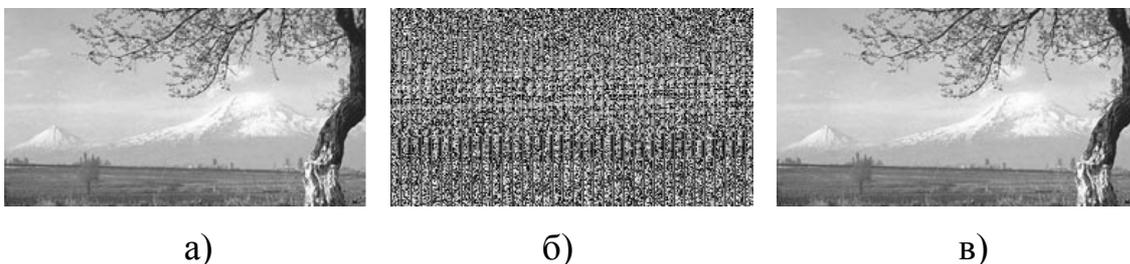


Рис. 4.10. Результаты исследования работоспособности алгоритма защиты графической информации: а – исходное изображение; б – сигнал в канале связи; в – восстановленное изображение

Таким образом, полученные результаты подтверждают работоспособность предложенного метода защиты графической информации, базирующегося на применении искусственной многослойной нейронной сети и техники глобальной реконструкции динамических систем. В работе [28] показана возможность применения многослойных нейронных сетей для решения задачи защиты информации в системах персонального радиовызова (пейджинговых системах). Теоретически метод глобальной реконструкции не накладывает ограничений на количество одновременно изменяемых параметров, однако на практике такие ограничения появляются в связи с конечной точностью вычисления μ^* . В частности, как показано в [29], не удастся добиться хорошей точности определения текущих значений μ^* при одновременной модуляции трех параметров для шага дискретизации $\Delta t = 0,025$ и количества поддиапазонов 256. Отмеченные ограничения относятся к чисто технической стороне практической реализации конфиденциальной передачи информационных сигналов по каналу связи.

4.3. Применение нейросетевых классификаторов для обработки данных физики высоких энергий

Важность и актуальность применения нейросетевых классификаторов (НС-классификаторов) в физическом эксперименте обуславливаются прежде всего возможностью создания очень быстрого интеллектуального триггера, способного в реальном масштабе времени выделять сложные много-частичные события. Кроме того, НС-классификаторы полностью используют всю доступную априорную информацию (в том числе и нелинейные корреляции признаков), а также обладают высокой устойчивостью относительно возможных неточностей и упрощений в обучающих последовательностях.

Рассмотрим архитектуру и методы обучения нейронных сетей, применяемых в НС-классификаторах.

Обучение рекуррентных сетей. Образы, не изменяющиеся при преобразовании (4.24), действуют как аттракторы и проецируют «искаженный» (пробный) двоичный N -мерный вектор на одно из базовых (запомненных) состояний, а именно на то, до которого расстояние Хэмминга наименьшее.

Определим в каждом узле сети локальное поле h_i^μ :

$$h_i^\mu = \sum_{j=1}^N w_{i,j} S_j^\mu. \quad (4.32)$$

Для того чтобы образ S^μ был стабильным, необходимо для всех нейронов выполнение условия

$$h_i^\mu S_i^\mu > 0, \quad i=1, N. \quad (4.33)$$

Можно предположить, что чем больше выравнивающее локальное поле (4.33), тем сильнее притяжение к образу S^μ и тем больше область притяжения. Следует заметить, что уравнение (4.24) инвариантно относительно умножения $w_{i,j}$ на любую константу того же знака, так как динамика сети определяется не величиной, а знаком суммы $\sum w S^\mu$. Поэтому величина выравнивающего поля (4.33) не определяет область притяжения. Вместо нее можно предложить следующий нормирующий параметр стабильности:

$$\gamma_i^\mu = \frac{h_i^\mu S_i^\mu}{|w_i|} \cdot |w_i| = \left(\sum_{j=1}^N w_{i,j} \right)^{1/2}, \quad (4.34)$$

который служит индикатором величины области притяжения. Для увеличения области аттрактивности необходимо увеличить γ_i^μ , $i=1, N$, т. е. решающее значение приобретает функция распределения параметров стабильности. Задачу обучения можно формализовать в виде, допускающем управление величиной области аттрактивности: найти такую матрицу весовых коэффициентов $w_{i,j}$, которая обеспечит выполнение условия $\gamma_i^\mu > G$ для всех $i=1, N$, где G некоторая константа, определяющая величину области притяжения образа S^μ . Конечно, величина области аттрактивности будет зависеть как от числа запомненных образов, так и от размеров сети. Однако возможность варьировать важнейшим параметром ассоциативной памяти открывает широкие перспективы для понимания механизмов, лежащих в основе интеллектуальных способностей моделей нейронных сетей.

Рассмотрим алгоритмы разового обучения НС. Примерами таких алгоритмов являются алгоритм Хопфилда

$$w_{i,j} = - \sum_{\mu=1}^M S_i^\mu S_j^\mu \quad (4.35)$$

и декоррелирующий алгоритм

$$w_{i,j} = \sum_{\mu,\nu}^M (R^{-1})^{\mu\nu} S_i^\mu S_j^\nu, \quad (4.36)$$

$$R^{\mu\nu} = N^{-1} \sum_{i=1}^N S_i^\mu S_i^\nu,$$

где обучение проводится по M образам сразу для всех нейронов сети. Алгоритм Хопфилда не способен распознавать без ошибок даже небольшое количество коррелированных прототипов, алгоритм (4.36) распознает до N образов безошибочно, однако не позволяет управлять областью притяжения, что, как было сказано выше, имеет решающее значение при построении распознающих систем.

Основной особенностью другого класса обучающих алгоритмов является вычисление параметра стабильности (4.34) для всех нейронов, затем, в зависимости от выполнения условия $\gamma_i^\mu > G$, – модификация элементов матрицы связей W . Для значений стабилизирующего параметра $G \in (0 - 1,5)$ обучение завершается за несколько итераций, однако для значений $G > 1,5$ некоторое небольшое число нейронов обучить не удастся: в процессе обучения с некоторого момента начинаются ассциляции и изменение распределения γ^μ прекращается.

Можно ввести понятие надежности обучения. Если в процессе обучения для всех i выполняется условие

$$\gamma_i^\mu > \eta G, \quad \eta \in (0-1), \quad (4.37)$$

то будем говорить, что цели обучения достигнуты с надежностью η . Модификация элементов матрицы связей выполняется в соответствии с выражением (4.38), если $\gamma_i^\mu < \eta G$

$$w_{i,j}(t+1) = w_{i,j}(t) + \sigma w_{i,j}, \quad (4.38)$$

$$\sigma w_{i,j} = f(w_{i,j}, G) S_i^\mu S_j^\mu,$$

где t – номер итерации. Конкретный вид функции f выбирается с целью ускорения обучения, в частности, для небольших значений G скорость обучения значительно увеличивается, если величина шага выбирается пропорционально $(\gamma_i^\mu - G)$.

На рис. 4.11 приведены результаты исследования эффективности алгоритмов обучения рекуррентных сетей. Были проведены вычислительные эксперименты по распознаванию букв на решетке, состоящей из 100 нейронов (10×10). Уровень случайного шума варьировался от 20 до 40 %, константа Гарднера от 0 до 2,5, надежность обучения составляла 90 % ($\eta = 0.9$). Вероятности ошибок вычислялись по 100 независимым экспериментам для каждого алгоритма, значения шума и «алфавита».

На рис. 4.11 представлены прототипы и пробные (искаженные) образы. Зависимость времени обучения (числа итераций) от значений стабилизирующей константы показана на рис. 4.12. Для несхожих букв *F* и *T* (расстояние Хэмминга $R_H = 0,28$) обучение заканчивается быстрее чем для более близких букв *F* и *E*, для которых $R_H = 0,08$. Заметим, что этот результат подтверждается некоторыми психологическими теориями различения, в которых, в частности, указывается, что при выборе между двумя объектами предъявление сходного раздражителя приводит к ухудшению качества распознавания.

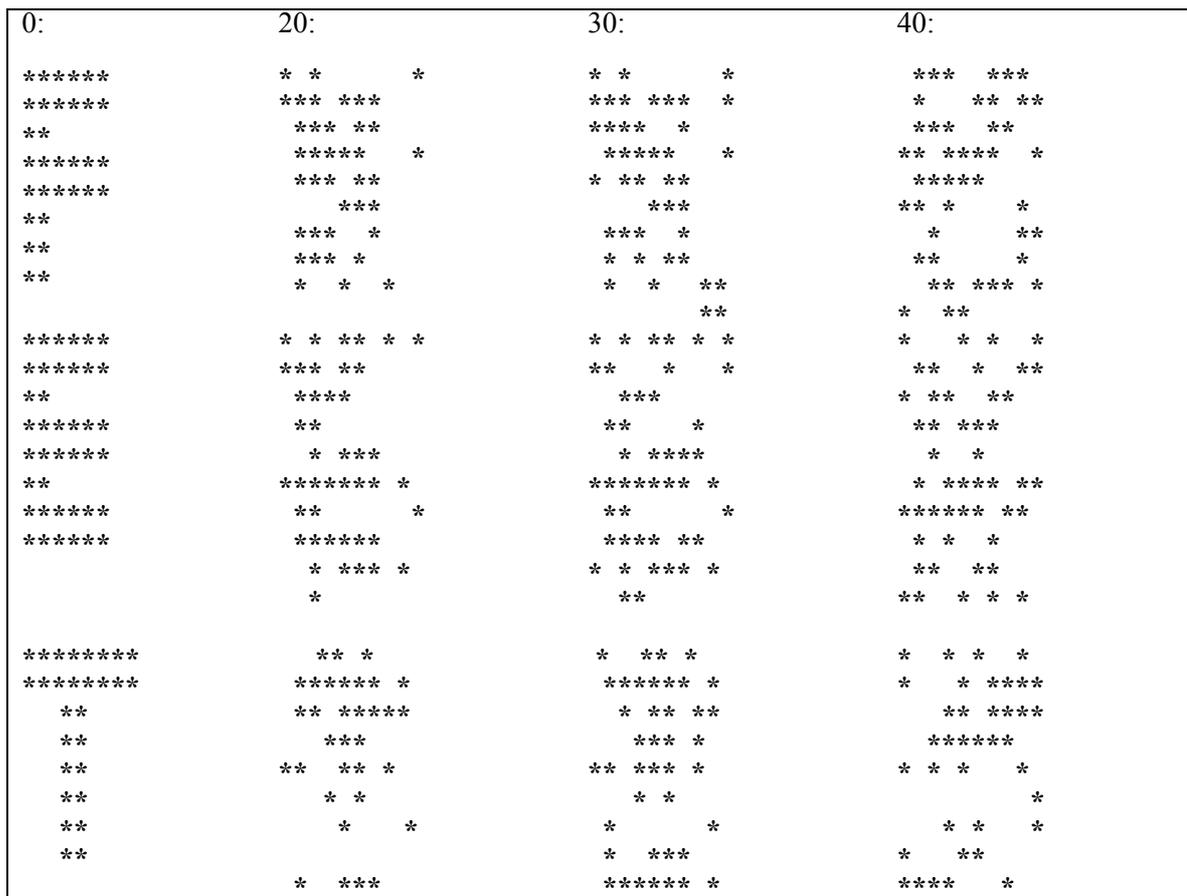


Рис. 4.11. Прототипы и «искаженные образы» (уровень случайного шума 20, 30 и 40 %)

Как правило, процесс вспоминания заключается в выборе из ряда возможных альтернатив с торможением побочных, произвольно возникающих связей, а забывание и неправильное вспоминание является следствием торможения следов, оставленных в процессе обучения (запечатления) побочными (интерферирующими) воздействиями.

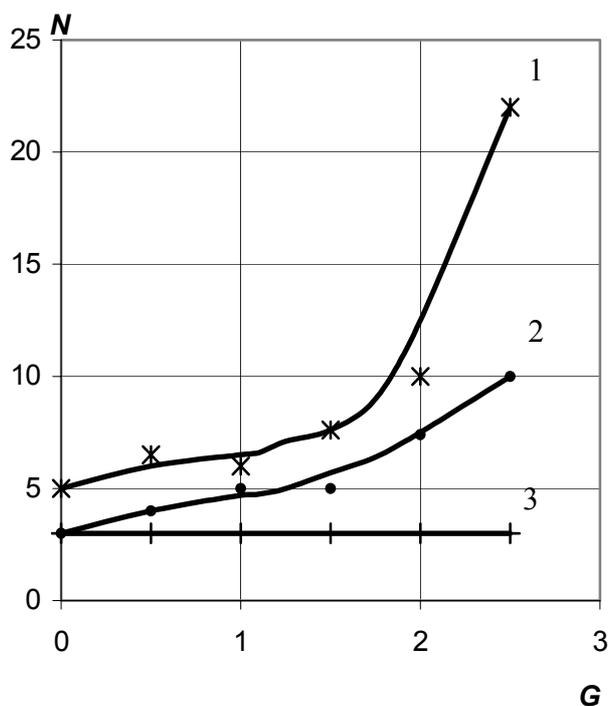
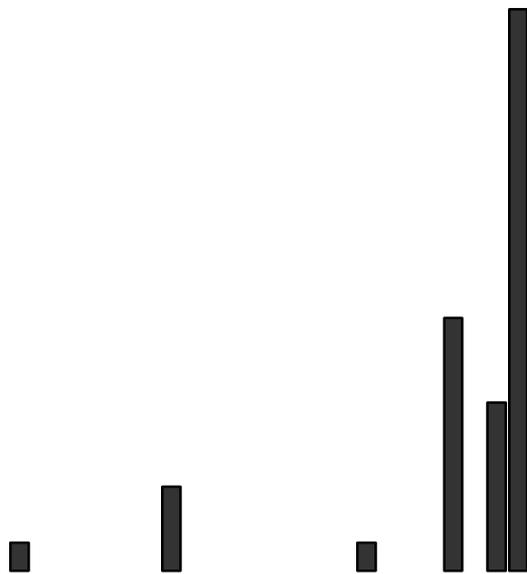


Рис. 4.12. Время обучения рекуррентной нейронной сети распознаванию образов: 1 – для образцов F, E, T ; 2 – для образцов F, T ; 3 – для образцов F, E

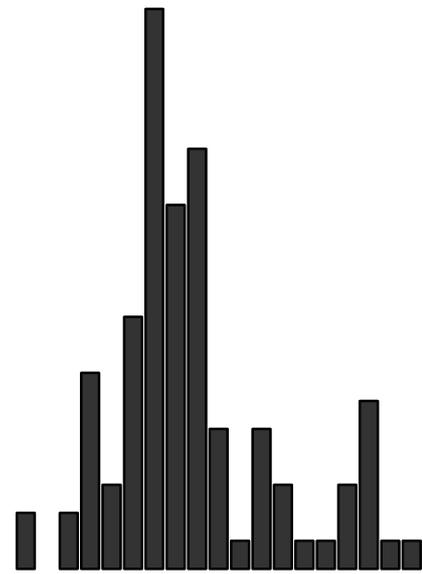
Эта теория согласуется с тем, что время обучения сети резко увеличивается при добавлении буквы E , интерферирующей с буквой F .

На рис. 4.13 представлены распределения параметров стабильности для различных алгоритмов обучения для трех прототипов. Алгоритм Хопфилда не способен безошибочно распознавать буквы, так как среди γ_i^{μ} есть отрицательные значения, то есть прототип не является инвариантом относительно динамики сети. Декоррелирующий алгоритм позволяет безошибочно распознать все три образа, алгоритмы класса Э. Гарднер также обеспечивают условие обучения. Кроме того, для значения константы $G=2,5$ распределение величин γ значительно правее от нуля по сравнению со значением $G=0$, но для этого требуется большее время обучения.

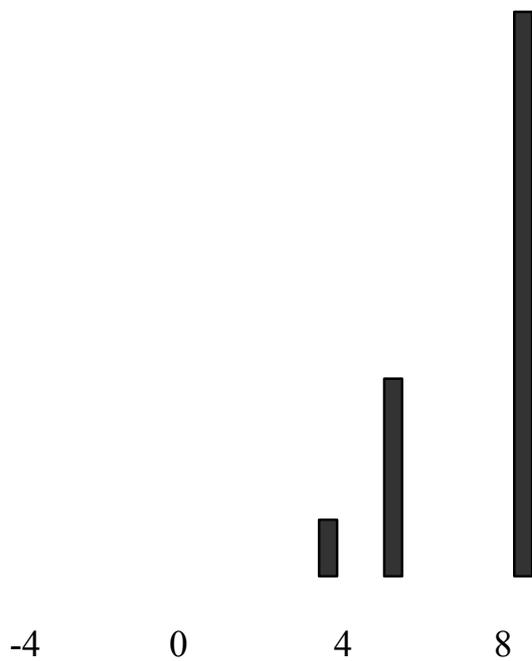
Алгоритм Хопфилда



Алгоритм класса Э. Гарднер,
 $G=0, \eta = 0.9$



Декоррелирующий алгоритм



Алгоритм класса Э. Гарднер,
 $G=2.5, \eta = 0.9$

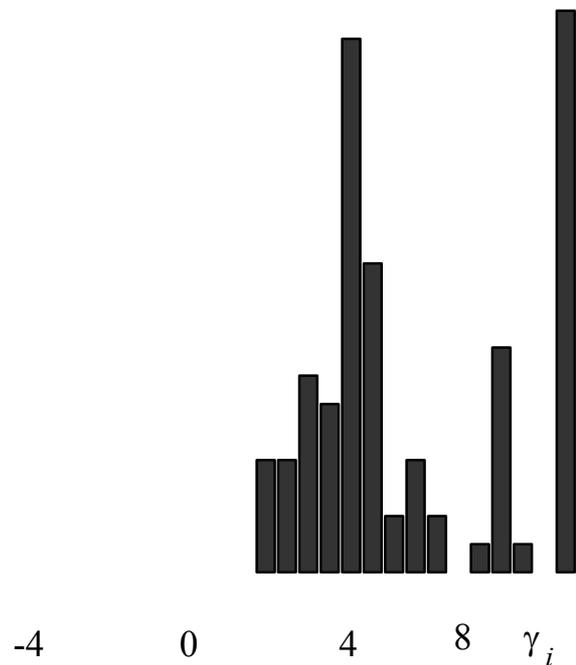


Рис. 4.13. Частотная гистограмма параметра стабильности, решетка размерами 10×10 , число образов – 3

На рис. 4.14 представлены вероятности ошибочной классификации в зависимости от величины константы Гарднер. С увеличением константы качество распознавания улучшается, однако если рассмотреть вероятности ошибок для отдельных образов, то можно заметить, что существует оптимальное значение G , после которого качество распознавания ухудшается. Это означает, что области аттрактивности образов уже пересекаются.

Последовательные многослойные сети. Применение рекуррентных сетей в физике высоких энергий ограничено, так как возможные состояния нейронов фиксированы, что затрудняет непосредственный ввод экспериментальной информации в нейронную сеть. Гораздо более перспективными с этой точки зрения являются последовательные сети, производящие обработку произвольной числовой информации. Кроме того, эти сети имеют очень большие возможности обучения, а также допускают непосредственное сравнение с техникой непараметрической байесовской классификации и, таким образом, обеспечивают преемственность и непрерывность в разработке новых информационных технологий.

На вход сети подается числовая информация об исследуемых объектах или процессах (показания детекторов, значения измеренных признаков и т.д.). Число нейронов в первом входном слое равно числу признаков. На вход каждого нейрона последующего слоя подается взвешенная сумма состояний предыдущего слоя:

$$IN_i^{l+1} = \sum_{j=1}^{N(l)} w_{i,j} OUT_j^l, \quad i=1, \dots, N(l+1), \quad l=1, \dots, L, \quad (4.39)$$

где l – номер слоя; L – число слоев в сети; $N(l)$ – число нейронов в l -м слое; OUT_j^l – состояние (значение выходной функции) j -го нейрона l -го слоя. Заметим, что в отличие от рекуррентных сетей $w_{ij} \neq 0$, т. е. помимо коэффициентов связей w_{ij} каждый нейрон характеризуется некоторым пороговым значением.

Выход нейрона (кроме первого слоя, который не преобразует входной сигнал) формируется с помощью нелинейной, так называемой сигмоидной функции:

$$OUT_i^l = \frac{1}{1 - \exp(-IN_i^l)}, \quad i=1, N(l), \quad l \neq 1. \quad (4.40)$$

С помощью определенного таким образом соотношения вход/выход данные от входного слоя через промежуточные (скрытые) слои поступают на выходной нейрон, значение сигнала которого используется для классификации поданной на вход информации.

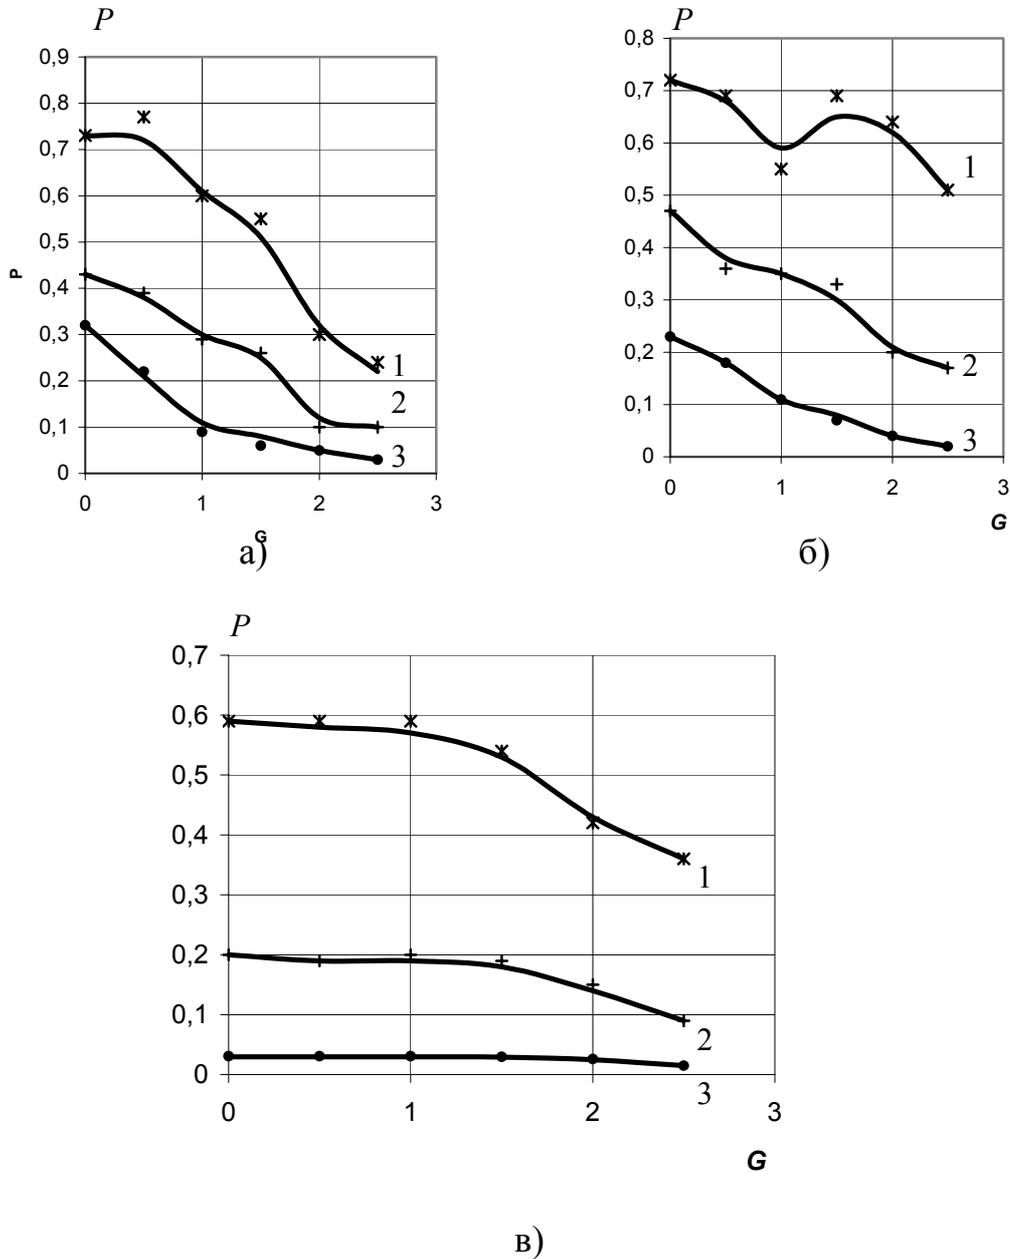


Рис. 4.14. Распознавание различных комбинаций букв рекуррентными сетями при варьировании уровня случайного шума: а – для образов F и E; б – для образов F, E, T; в – для образов F, и T; 1 – уровень 04; 2 – уровень 03; 3 – уровень 02

Такая архитектура обработки данных, сочетающая линейное суммирование сигналов с существенно нелинейным преобразованием в скрытых

слоях, позволяет учесть всю различительную информацию в многомерных экспериментальных данных, в том числе нелинейные корреляции.

Отметим, что нейронная сеть, состоящая из двух слоев (скрытый слой отсутствует), реализует хорошо известный в прикладном статистическом анализе классификатор – линейную дискриминантную функцию, производящую классификацию путем разделения признакового пространства кусочными гиперповерхностями.

Для обучения сети используются данные известной принадлежности. Это могут быть результаты модельных или калибровочных испытаний. Начальные значения весовых коэффициентов w_{ij} приравниваются к случайным числам из гауссовского распределения с нулевым средним и небольшой дисперсией. Выход такой случайно обученной сети равен для всех классов одной и той же величине ($OUT(l) = 0.5$) и, естественно, классификация невозможна.

В практических приложениях обучение нейронной сети производится путем многократного предъявления обучающих последовательностей и модификации коэффициентов w_{ij} . После каждого цикла итерационного процесса вычисляется функция качества обучения

$$Q = \sum_{k=1}^K \sum_{i=1}^{M_k} (OUT_i^k - OUT_{true}^k)^2, \quad (4.41)$$

где OUT_i^k – значение выходного нейрона сети при обработке i -го образа k -го класса; M_k – число образов в обучающей выборке k -го класса; K – число классов; OUT_{true}^k – «истинное» значение выходов сети для образов k -го класса.

Минимизация функционала (4.41) обычно проводится методом обратного распространения. Основным недостатком такого типа алгоритмов минимизации является сходимость к локальному минимуму. Поэтому в данном случае применяется случайный поиск с возвратом при неудачном шаге и с адаптацией величины случайного шага, позволяющий выходить из области локального минимума и продолжать поиск глобального минимума. Поиск ведется в пространстве параметров сети размерности $NTOT$:

$$NTOT = \sum_{l=2}^L N(l) + \sum_{l=1}^{L-1} N(l)N(l+1). \quad (4.42)$$

Алгоритм поиска оптимальных параметров состоит из следующих шагов: 1) с помощью генератора случайных чисел выбирается номер пара-

метра, который будет модифицироваться; 2) вычисляется величина приращения

$$\sigma = \eta f(Q) (RND - 0.5), \quad (4.43)$$

где RND – случайная величина, равномерно распределенная в интервале (0-1); $f(Q)$ – степенная функция, контролирующая величину случайного шага по мере приближения к глобальному минимуму; η – нормировочная константа.

Итерационный процесс заканчивается, когда практическое изменение функции прекращается. Полученные в процессе обучения значения коэффициентов w_{ij} используются для классификации данных неизвестной принадлежности.

Таким образом, рассмотренные модели нейронных сетей представляют собой специальный класс статистических классификаторов, для анализа которых можно использовать стандартную методику прикладной статистики. Однако, несмотря на большое сходство, нейронные сети имеют некоторое преимущество по сравнению с алгоритмами байесовской классификации с непараметрическим оцениванием многомерной функции плотности вероятности.

По-видимому, эффекты малого объема выборок менее заметны при использовании нейросетевых классификаторов (НС-классификаторов) – они более устойчивы к возможным ошибкам и отклонениям в обучающих выборках. В обучении НС участвуют все классы, тогда как в классификаторах, основанных на оценивании плотности вероятности, для каждого класса используется только своя выборка. Поэтому можно ожидать, что НС-классификаторы превзойдут статистические, особенно в случае большого числа признаков и не очень больших обучающих последовательностей.

К сожалению, до настоящего времени нет теоретических результатов и методик конструирования НС-классификаторов. Не получена зависимость вероятной ошибки классификаторов в зависимости от точности определения параметров сети, неясно влияние выбора формы нелинейной сигмоидной функции на результаты классификации. Вопрос выбора конфигурации сети (числа скрытых слоев и числа нейронов) также остается открытым. Поэтому в рассматриваемых НС-классификаторах используется простейшая конфигурация сети с одним скрытым слоем и числом нейронов в нем, равным 3, 5 или 7.

В качестве тестового примера выбрана задача оценивания байесовского риска при классификации выборок из гауссовского распределения с единичной дисперсией и средним, равным нулю и единице (теоретическое значение вероятности ошибочной классификации $ВОК = 0,3086$).

Обучение проводилось на выборках размером 500. Оценивание риска проводилось с помощью 20 независимых выборок размером 500 из тех же распределений. На рис. 4.15 представлена обучающая выборка, на рис. 4.16 – гистограмма выходов нейронной сети. Результаты классификации одной из контрольных выборок представлены на рис. 4.17 (конфигурация сети – $1::3::1$, вероятность ошибки = 0.3, если точка решения $D = 0.5$).

Полученное совпадение значений вероятности ошибок для классификаторов на нейронных сетях ($R^{NN} = 0.3087 \pm 0.0024$) с $ВОК$ байесовского классификатора может служить основанием для применения НС-классификаторов для обработки более сложных реалистических задач.

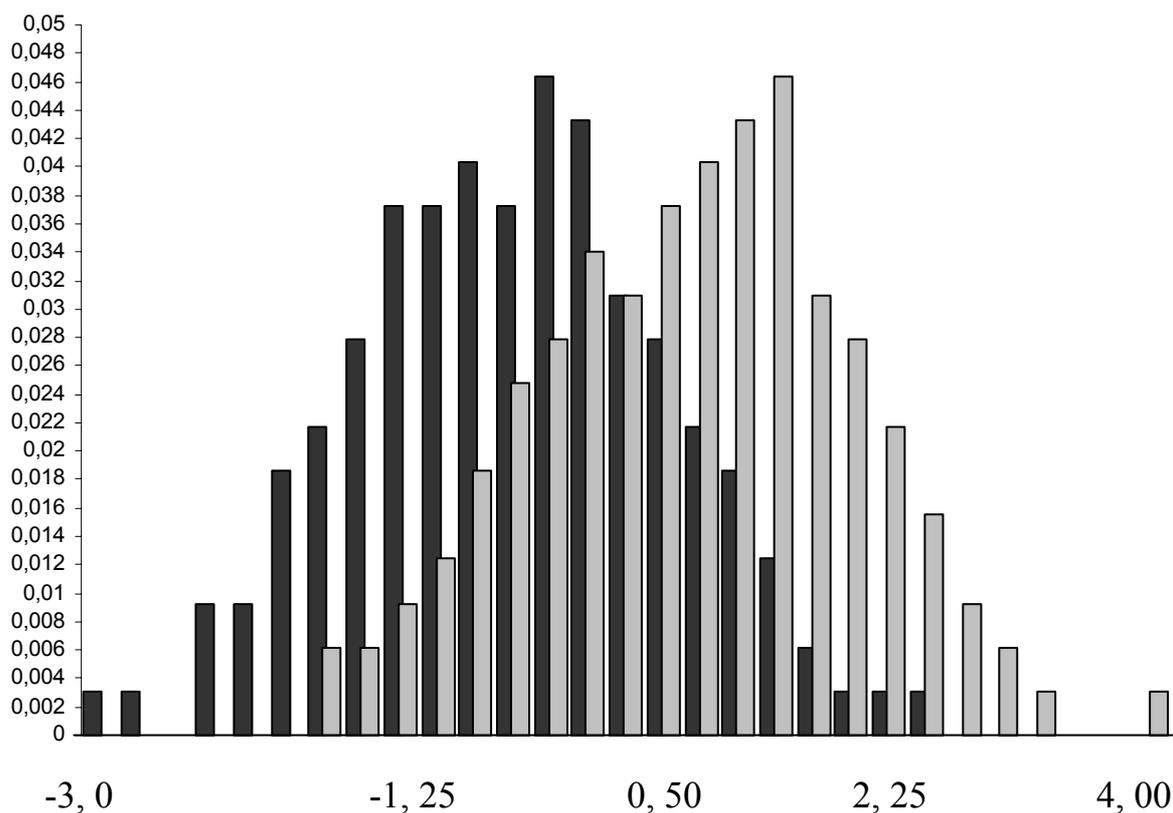


Рис. 4.15. Гистограмма двух выборок из гауссовского распределения, использованных для обучения нейронной сети: ■ – $N(0,1)$ – 1000 событий; ■ – $N(1,1)$ – 1000 событий; ■ – область перекрытия, вероятность ошибки = 0,3085

Одной из таких задач является применение НС-классификаторов для исследования возможности выделения каналов рождения b кварков в реакции

$$e^+ e^- \rightarrow q\bar{q} \quad (4.44)$$

при $E_{cm} = 14$ ГэВ на фоне рождения кварков (u, d, s, c). Отношение сигнал/шум составляет 1/10. Для обучения использовалось 4 000 событий, контрольная выборка составляла 6 000 событий, число используемых признаков – 5. Сеть конфигурации 5//3//1 дала несколько лучшие результаты по сравнению с сетью 3//2//1 и была намного лучше, чем линейная дискриминантная функция – 5//1.

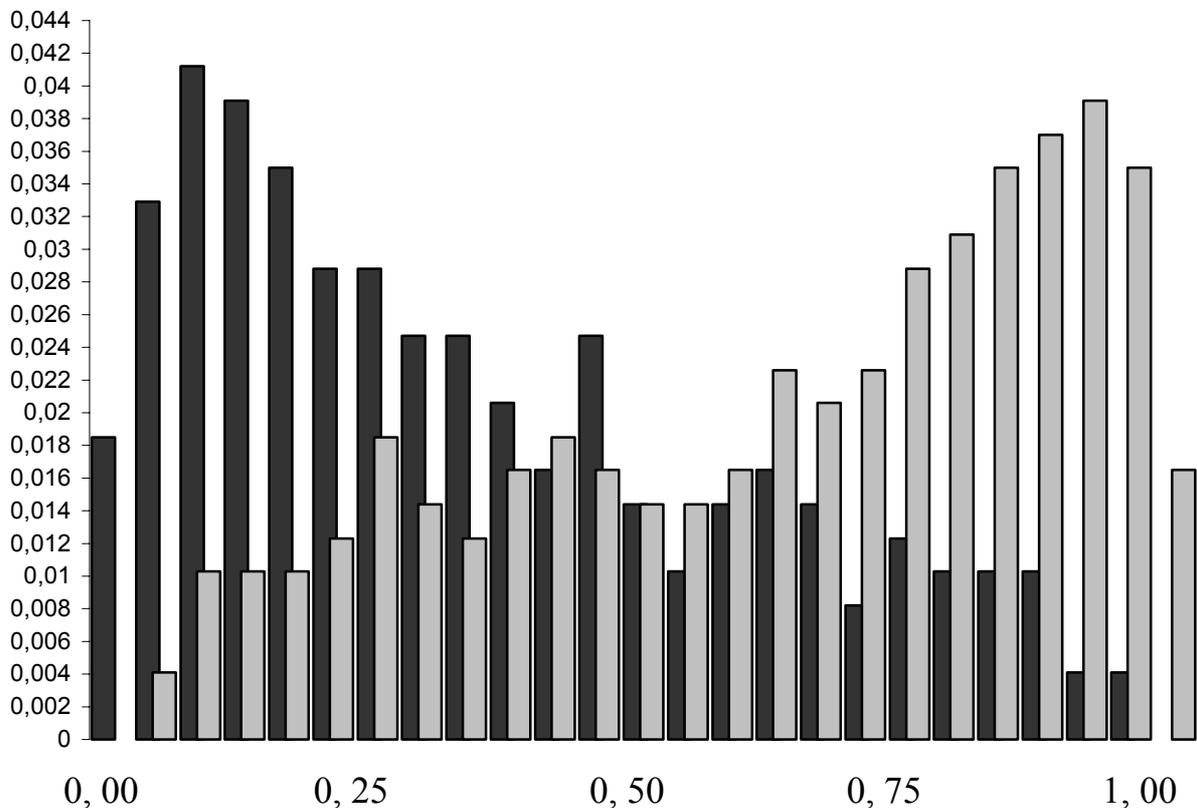


Рис. 4.16. Гистограмма значений выхода нейронной сети:

■ – события из выборки с нулевым средним; ■ – события из выборки с единичным средним; ■ – область перекрывания, вероятность ошибки = 0,3085

Другое применение НС-классификаторов связано с задачей исследования возможности разделения кварковых и глюонных струй в $e^+ e^-$ анни-

гиляции при $E_{cm} = 630$ ГэВ. Используя в качестве признаков показания ячеек калориметра вокруг центра струи (всего $7 \times 7 = 49$ признаков), удалось повысить достоверность выделения кварковых струй с 65 до 85 %. Конфигурация используемой сети – 49//10//1.

Одной из первых попыток применения нейросетевых классификаторов к реальному эксперименту было определение вершины взаимодействия в $p\bar{p}$ -столкновениях на Тэватроне (эксперимент E375 с дрейфовой камерой).

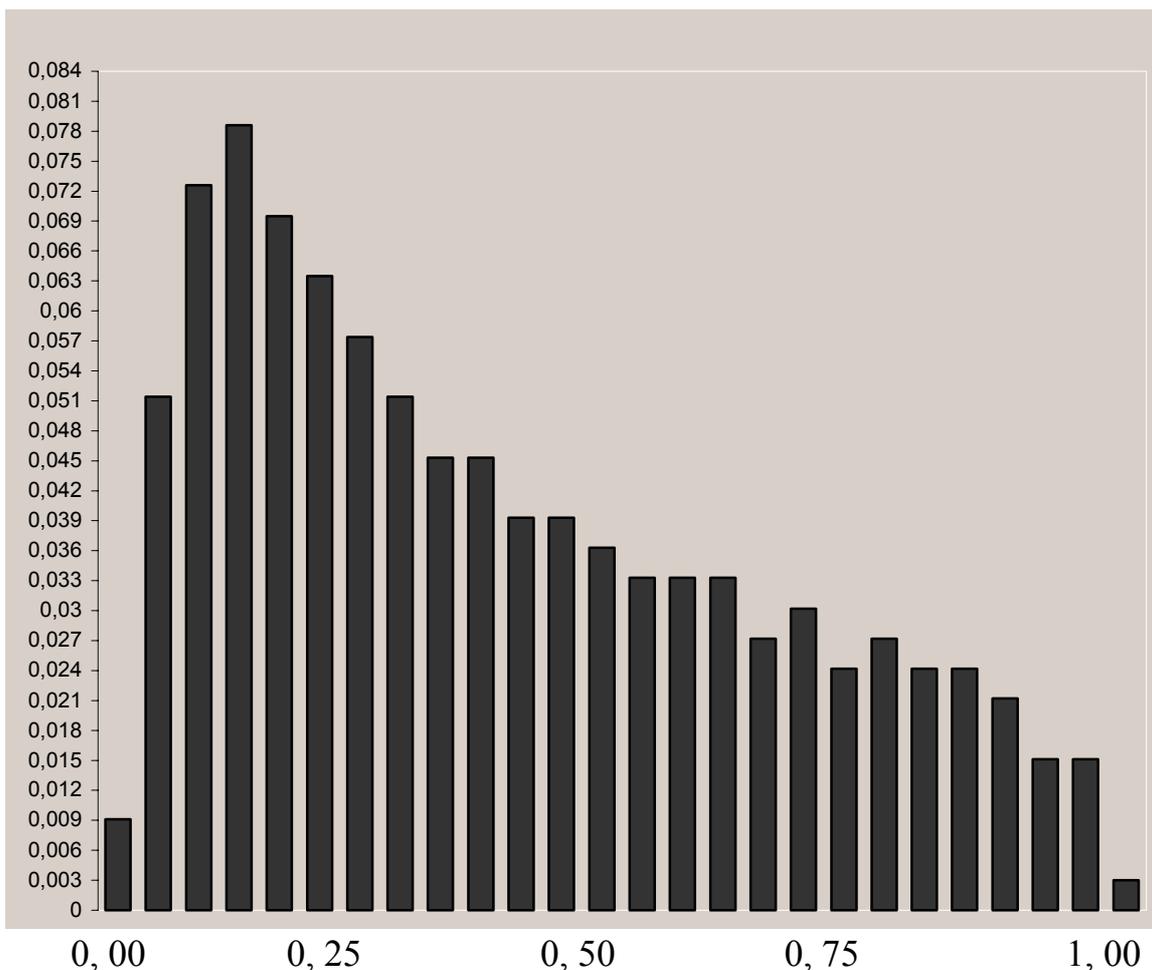


Рис. 4.17. Классификация контрольной выборки с помощью предварительно обученной сети: ■ – $N(0,1)$ – 5000 событий

Обучение сети проводилось с помощью 12 000 специально отобранных экспериментальных данных, после 4 миллионов итераций сеть проверялась по независимой экспериментальной выборке. Точность восстановления вершины оказалась сравнимой с точностью, достигнутой в off-line-

анализе. Конфигурация сети – 18//128//62. Большое число нейронов в скрытом слое обусловлено тем, что предполагается использовать серийно выпускаемый нейросетевой чип (Intel ETANN) для off-line-анализа, число нейронов в слоях которого равно 128. Большое число нейронов в выходном слое связано с тем, что решается не задача классификации – выбор одного из конечного множества вариантов, а задача оценивания – определение непрерывно распределенной величины и координаты вершины события.

В физике космических лучей основная задача анализа также сводится к выделению событий того или иного типа. Например, задачи определения массового состава, первичного космического излучения по данным рентген-эмульсионных камер и широких атмосферных ливней и задача регистрации потока γ -квантов от точечных источников. Для решения последней задачи, кроме того, важно иметь также быстрый интеллектуальный триггер, так как интенсивность фоновых событий (изображений черенковских вспышек от Гэвных протонов и ядер) довольно высока. Для сокращения числа записываемых с целью последующего анализа событий применяется электронный триггер, уменьшающий область допустимых прицельных параметров и, следовательно, светосилу установки.

Ниже приводятся некоторые результаты применения НС-классификаторов для анализа данных черенковских телескопов и сравнения методов байесовской и НС-классификаций. Исследовались возможности дискриминации изображений Черенковских вспышек от космических лучей при наблюдении потока γ -квантов от Крабовидной туманности телескопом обсерватории Whipple.

Обучение сети проводилось с помощью данных моделирования γ -квантов и реальных изображений, генерированных протонами (зарегистрированных телескопом, направленным в область звездного неба, где заведомо нет γ -квантов). Для обучения использовалось по 500 событий, контрольная выборка состояла из 500 экспериментальных событий. Результаты обучения (рис. 4.18) свидетельствуют о достаточно хорошем разделении классов. На рис. 4.19 приведены кривые эффективности полезных событий и примеси фоновых. Так как в эксперименте фон превышает сигнал на 2 порядка, то важно подавить фон более чем в 100 раз, сохранив хотя бы 50 % сигнала. С помощью НС-классификатора эта задача была решена – примесь фона составила 0,4 % при значении решающей границы $D = 0,07$,

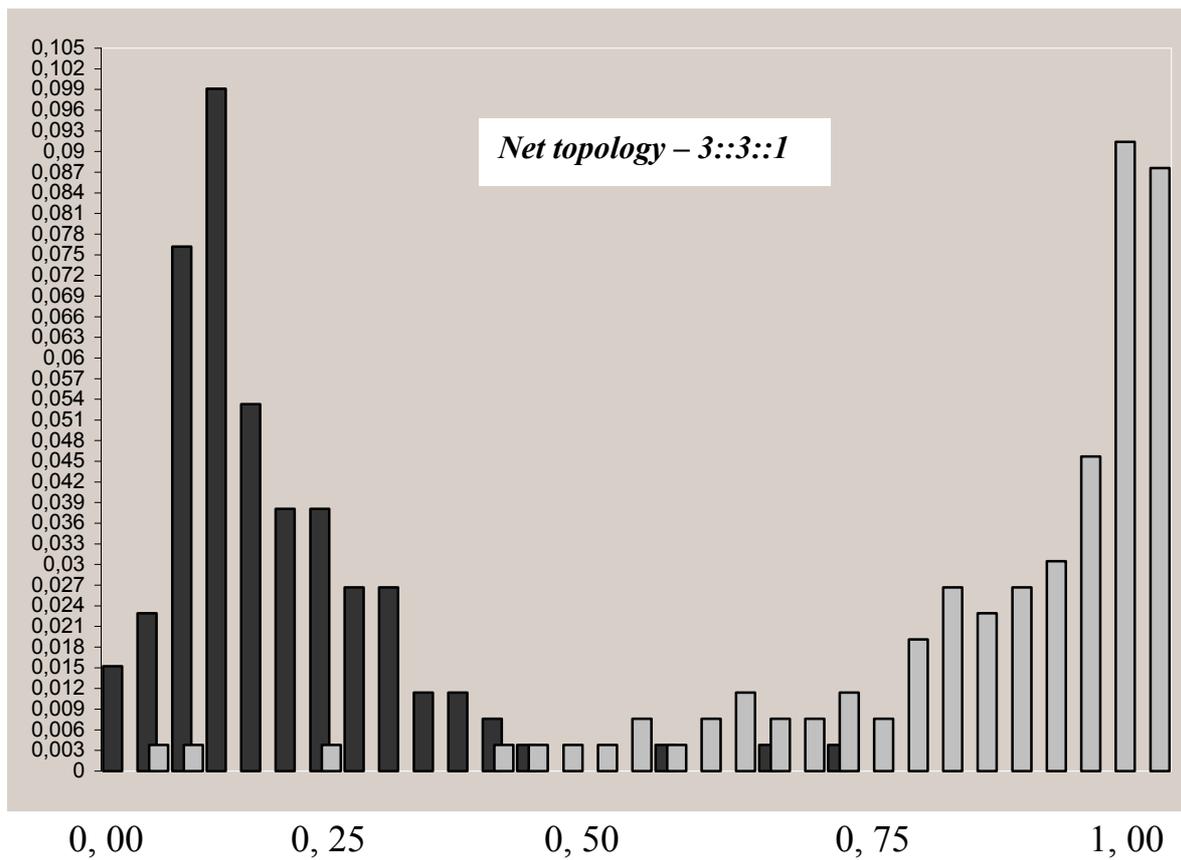


Рис. 4.18. Гистограмма выхода нейронной сети:

- – данные моделирования – γ -ливни ~ 500 событий;
 - – данные моделирования – P-ливни ~ 500 событий;
- используемые переменные – *width, length, azwidth*

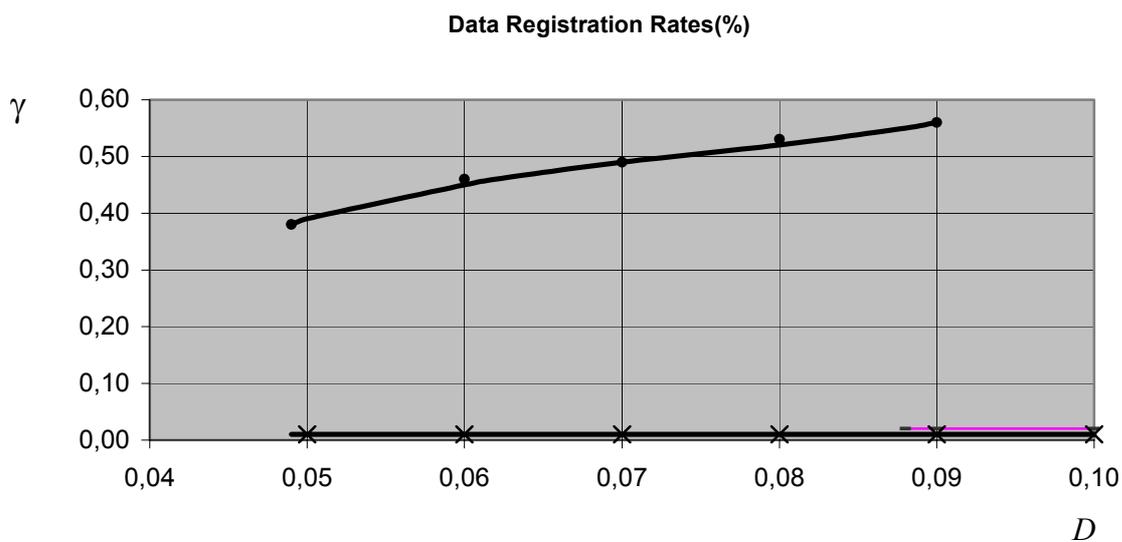


Рис. 4.19. Результаты классификации черенковских изображений

одновременно сохранилось более 50 % γ -событий. Байесовский анализ той же контрольной выборки дал несколько худшие результаты – 0,6 % примеси фона при 50 % эффективности регистрации сигнала.

Конфигурация сети 3//3//1 позволяет получить лучшие результаты, чем 3//5//1. Обучение заканчивалось через 500 итераций. Время классификации одного события составило приблизительно 1 микросекунду, тогда как при применении байесовских решающих правил с оцениванием функции плотности вероятности методом Парзеновских ядер на обработку одного события требуется 1 секунда.

4.4. Нейросетевые устройства постоянной памяти

Известно большое количество работ, направленных на исследование принципов организации и функционирования нейронных структур. Однако рассматриваемые в этих работах модели в своем большинстве носят чисто теоретический характер с биологическим уклоном и направлены главным образом на исследование свойств и закономерностей нервной системы. Решение же вопроса построения технических систем памяти на нейронных сетях (НС) связано с необходимостью выбора единого подхода к построению запоминающих устройств (ЗУ) на НС, в частности на многослойных сетях нейронных элементов.

В иерархических системах памяти можно выделить широкий класс ЗУ, общим признаком которых является групповая последовательная запись блока информационного массива и произвольная выборка информации. К таким ЗУ можно отнести прежде всего постоянные ЗУ (ПЗУ), полупостоянные ЗУ (ППЗУ) и целый ряд буферных и сверхоперативных ЗУ (СОЗУ).

Если рассматривать эти ЗУ с позиций функционального подобия, то наиболее близко аналогичными признаками обладают обучаемые системы распознавания образов, в которых последовательный процесс обучения распознаванию может быть представлен эквивалентным процессу последовательной записи информации в ЗУ, а процесс распознавания входного образа – считыванию информации. Тогда пространством входных образов X будем считать пространство, содержащее массив адресных кодов $\bar{x}(n)$, пространством классов E (или указаний учителя) – пространство, содержащее массив информационных кодов $\bar{e}(n)$, подлежащих записи, а про-

странством решений X_k – пространство, содержащее массив кодов воспроизведенной информации $\bar{x}(n)$. При этом для ЗУ как системы распознавания образов адресная последовательность эквивалентна обучающей (при записи) и контрольной (при считывании) последовательностям, которые, в свою очередь, детерминированы и совпадают. В результате этого после обучения достигается частота ошибок (сбоев при считывании), равная нулю ($f_{ош} = 0$), или соответственно вероятность правильного считывания $P_{прав} = 1$. При считывании информации всегда выполняется условие

$$\bar{x}(n) = \bar{\varepsilon}(n), \quad (4.45)$$

где n – дискретный аргумент.

Запоминающее устройство, характеризующееся групповой последовательной записью и произвольным считыванием информации, можно рассматривать и реализовать как обучаемую систему распознавания образов (СР). При таком подходе ЗУ представляется состоящим из двух частей (рис. 4.20):

- разомкнутая базовая система распознавания (СР), под которой подразумевается многослойная СР с настраиваемыми параметрами (собственно обучаемая многослойная сеть пороговых элементов) без встроенного блока настройки параметров;
- блок настройки параметров, производящий непосредственную настройку параметров разомкнутой базовой СР (обучение).

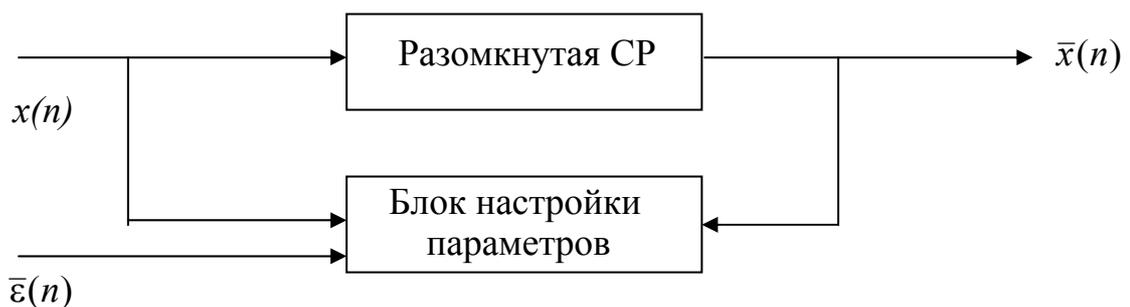


Рис. 4.20. Структурная схема ЗУ как обучаемой системы распознавания образов

Рассмотрим структурную организацию устройств постоянной памяти на НС. Для постоянного запоминающего устройства как системы распознавания применяется архитектура из N^* разрядных СР на два решения

(рис 4.21). При этом разрядные СР являются самостоятельными одноразрядными ПЗУ, имеющими общие принципы структурной организации.

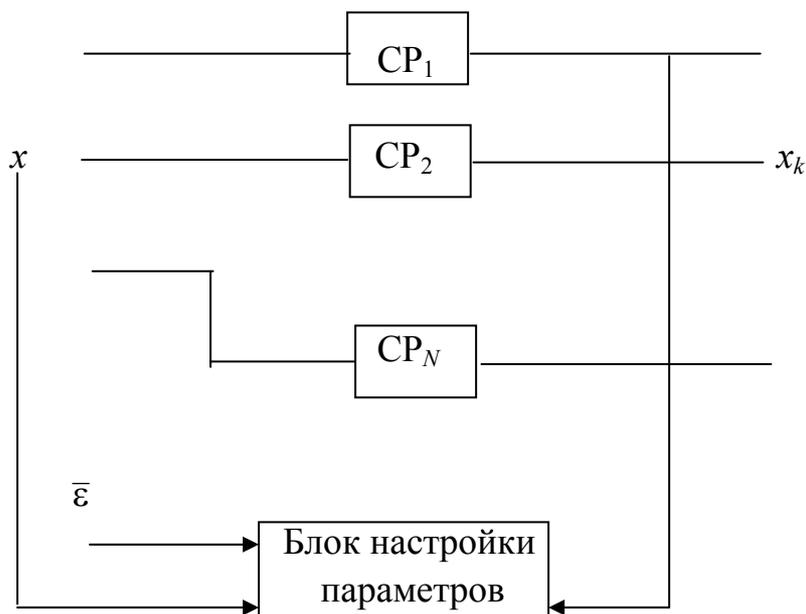


Рис. 4.21. ЗУ из N^* базовых СР с двумя решениями

Пусть в ПЗУ на адресный вход разрядной СР поступает последовательность многомерных векторов $\bar{x}(n)$, представляющая собой коды адресов (образов), по которым должна быть записана или считана определенная информация. Код каждого разряда вектора может принимать значения 0 или 1. При этом код каждого последующего вектора адреса отличается от предыдущего на единицу.

Обозначим через $x_{i\alpha}$ входную переменную, соответствующую i -му разряду α -го вектора адреса входной последовательности. Допустим, что число входов порогового элемента (ПЭ) равно разрядности адреса, т.е. $n=N$, а номер входа ПЭ соответствует номеру разряда вектора адреса. Для того чтобы вектор адресной последовательности можно было взаимно отделить, для каждого из них требуется, например, разная сумма произведений входных адресных переменных и весов на входе ПЭ. Условие, при котором такая сумма для последующего вектора всегда больше суммы предыдущего вектора, можно записать следующим образом:

$$G = \sum_{i=1}^n a_i x_{i\alpha} - \sum_{i=1}^n a_i x_{i(\alpha-1)} - a_n - \sum_{i=1}^n a_i, \quad (4.46)$$

где a_n – вес n -го входа ПЭ; i – номер входа ПЭ, соответствующий номеру разряда адреса.

При этом для получения постоянной разницы между суммами необходимо выполнение условия

$$g = \text{const} = a_n - \sum_{i=1}^{n-1} a_i = a_{n-1} - \sum_{i=1}^{n-2} a_i, \quad (4.47)$$

$$a_n - a_{n-1} - \sum_{i=1}^{n-2} a_i = a_{n-1} - \sum_{i=1}^{n-2} a_i. \quad (4.48)$$

Таким образом, требуемая емкость памяти определяет разрядность вектора адреса, которая, в свою очередь, определяет число входов ПЭ и соответственно набор значений весовых коэффициентов.

Автором данного учебного пособия разработана модель нейронного постоянного запоминающего устройства, суть работы которого заключается в следующем.

Пусть входной информационный массив задан в виде матрицы. Каждой строке X_i информационного массива поставлен в соответствие ключевой образ (ключ) K_i . Для обработки и хранения информации используется трехслойная (Q_1, Q_2, Q_3) нейронная сеть (НС). Каждый слой НС представляет собой матричную структуру размерностью 32×32 нейрона.

$$M = \begin{vmatrix} 11001001001\dots100 \\ 01010010010\dots101 \\ \dots \dots \dots \dots \\ 01010101010\dots111 \end{vmatrix}$$

Этап записи. На вход слоя Q_1 подается ключевой образ K_1 и первая строка входного массива X_1 (рис. 4.22). Сигнал со слоя Q_1 по связям передается на слой Q_2 , где производится его предварительная обработка. Затем выполняется передача образа со слоя Q_2 на слой Q_3 . В результате такой обработки первая строка информационного массива преобразуется в образ R_1 (рис. 4.23), который запоминается нейронами выходного слоя сети. Запись остальных строк массива M выполняется аналогичным образом. На рис. 4.24 показано состояние элементов выходного слоя (Q_3) после записи в нейронное ассоциативное ЗУ векторов X_1, X_2, \dots, X_{50} .

Этап выборки (воспроизведения). Для выборки вектора X_1 на слой Q_3 необходимо подать ключевой образ K_1 . Сигнал со слоя Q_1 передается на слой Q_3 , в результате чего активизируются нейроны, образующие образ R_1 . Обработка этого образа по определенному алгоритму позволяет восстановить вектор X_1 .

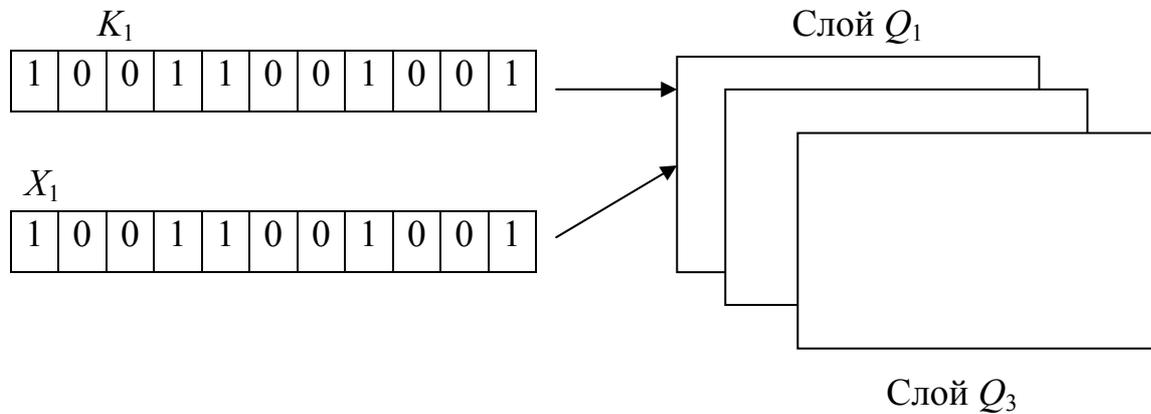


Рис. 4.22. Запись вектора X_1 в нейронную память

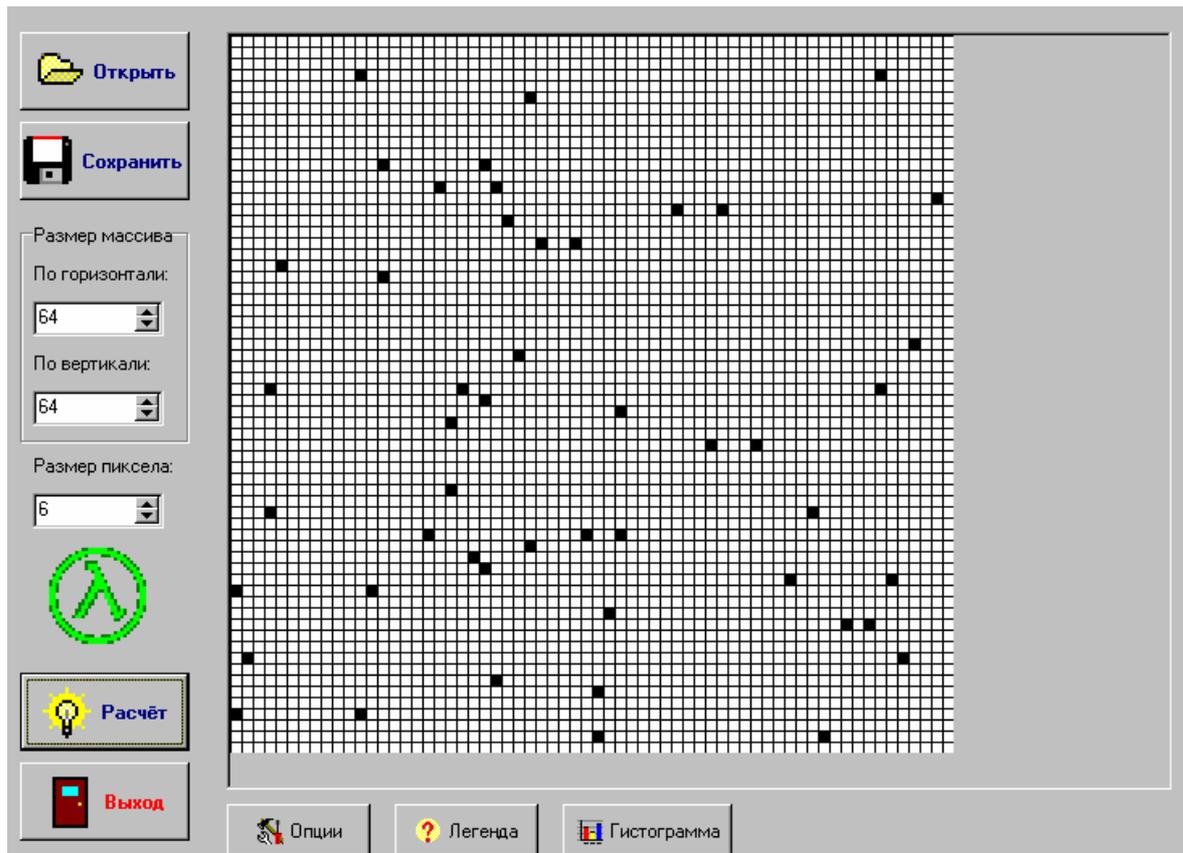


Рис 4.23. Состояние нейронов выходного слоя НС после записи вектора X_1 : □ – пассивный нейрон (0); ■ – активный нейрон (1)

Приведенная модель нейронного ассоциативного ЗУ основана на распределенном хранении информации. В распределенной памяти каждый запоминающий элемент или фрагмент запоминающей среды содержит следы многих образов (R_i). Иными словами, имеет место пространственное наложение образов в памяти. С другой стороны, каждый элемент записываемой информации распределяется по большой области запоминающей среды. Для того чтобы информация одного элемента не терялась в памяти в результате смешивания с информацией других элементов, необходимо, чтобы преобразования информации в процессе записи не затрагивали связи между элементами.

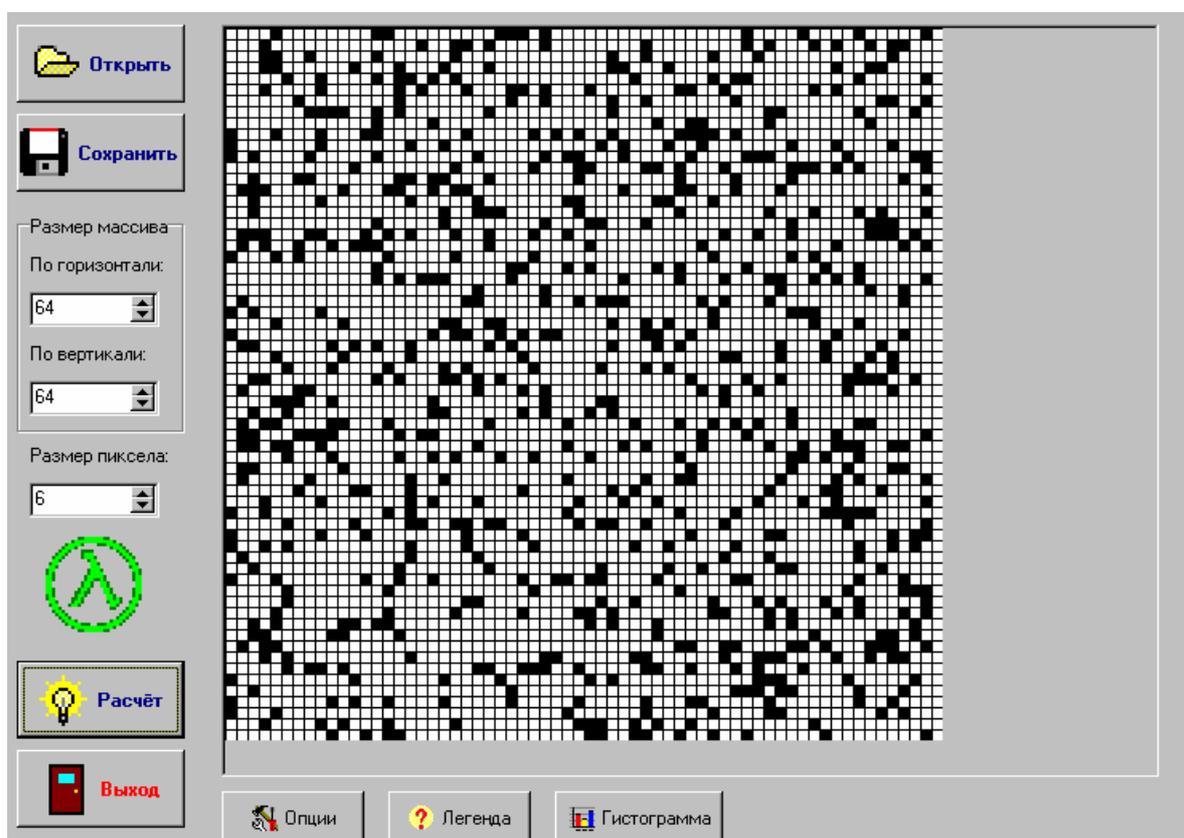


Рис 4.24. Состояние нейронов запоминающего слоя НС после записи в ассоциативную память 50 образов

В нейронной ассоциативной памяти запоминаемая информация «расплывается» по всей запоминающей среде в результате преобразования входных образов на слоях нейронной сети. Поэтому запоминающие элементы должны обладать способностью многократно изменять свои состоя-

ния под влиянием многих запоминаемых образов. При этом важнейшее значение имеет то обстоятельство, что при записи одновременные и очень малые изменения происходят сразу в очень большом количестве запоминающих элементов. Именно благодаря этому весьма широкий динамический диапазон переменных элементов памяти можно использовать для хранения большого числа образов.

В процессе выборки записанная информация восстанавливается как сумма многих «следов памяти». Отсюда следует важное свойство распределенной памяти: поскольку выходной образ формируется путем опроса очень большого числа отдельных элементов, локальные искажения ключевых образов оказываются статистически сглаженными.

Можно показать, что имеются случаи, когда выборка из распределенной памяти с большим числом записанных образов осуществляется без взаимных помех. В общем случае, однако, при выборке из распределенной памяти выходной образ всегда содержит шум или искажения. Уровень шума при выборке информации из нейронного ассоциативного ЗУ зависит от величины порога активизации нейронов. Для определения оптимального порога разработан следующий метод.

Рассмотрим случай, когда выходной образ содержит полезную информацию (образ) и фон (два информационных класса). Предположим, что области фона и объекта (в данном случае выходного образа) однородны, а на границах принадлежность нейронов к фону или объекту характеризуется высокой неопределенностью (так называемой неопределенностью класса, или энтропией). Введем критериальную функцию, учитывающую однородность областей и энтропию. Минимум этой функции соответствует величине оптимального порога активизации нейронов. Функция энтропии имеет вид:

$$H_t(g) = -\frac{\theta(t)p_{0,t}(g)}{p_t(g)} \log \frac{\theta(t)p_{0,t}(g)}{p_t(g)} - \frac{(1-\theta(t))p_{b,t}(g)}{p_t(g)} \log \frac{(1-\theta(t))p_{b,t}(g)}{p_t(g)}, \quad (4.49)$$

$$\text{где } p_{0,t} = \frac{1}{\sqrt{2\pi}\sigma_0(t)} e^{-\frac{(g-m_0(t))^2}{2\sigma_0^2(t)}}, \quad p_{b,t} = \frac{1}{\sqrt{2\pi}\sigma_b(t)} e^{-\frac{(g-m_b(t))^2}{2\sigma_b^2(t)}}, \quad (4.50)$$

$$p_t(g) = \theta(t)p_{0,t}(g) + (1 + \theta(t))p_{b,t}(g), \quad \theta(t) = \frac{|F_{0,t}|}{mn}, \quad |F_{0,t}| = \{c \mid c \in C, f(c) \geq t\},$$

где t – порог, $t \in \Gamma$; $g \in \Gamma$ и изменяется от минимального до максимального значения из Γ для каждого t ; $m_{o,t}, m_{b,t}, \sigma_{o,t}, \sigma_{b,t}$ – математическое ожидание и среднеквадратическое отклонение интенсивностей при пороге t для объекта и фона соответственно; $f(c)$ – значение сигнала на входе нейрона c , $f(c) \in \Gamma$; операция $|\dots|$ – определение количества членов в множестве.

Функция однородности областей:

$$X(i) = \sum_{\forall c \in C, f(c)=i} \mu_\tau(c), \quad Y(i) = \sum_{\forall c \in C, f(c)=i} (1 - \mu_\tau(c)), \quad \mu_\tau(c) = \frac{\sum_{d \in C} \mu_a(c,d) \mu_\varphi(c,d)}{\sum_{d \in C} \mu_a(c,d)}, \quad (4.51)$$

где $\mu_a(c,d)=1$, если нейроны c и d отличаются только по одной ординате

на 1, в противном случае $\mu_a(c,d)=0$; $\mu_\varphi(c) = 1 - \frac{|D^+(c,d) - D^-(c,d)|}{\sum_{e \in B_{cd}(c)} \varpi_{cd}(\|c - e\|)}$;

$$D^+(c,d) = \sum_{\substack{e \in B_{cd}(c) \\ e' \in B_{cd}(d) \\ c-e=d-e'}} |1 - W_\varphi(\delta_{cd}^+(e, e'))| \varpi_{cd}(\|c - e\|); \quad (4.52)$$

$$D^-(c,d) = \sum_{\substack{e \in B_{cd}(c) \\ e' \in B_{cd}(d) \\ c-e=d-e'}} |1 - W_\varphi(\delta_{cd}^-(e, e'))| \varpi_{cd}(\|c - e\|); \quad (4.53)$$

$$\delta_{cd}^+(e, e') = \begin{cases} f(e) - f(e'), & \text{если } (f(e) - f(e')) > 0, \\ 0, & \text{в противном случае} \end{cases} \quad (4.54)$$

$$\delta_{cd}^-(e, e') = \begin{cases} f(e) - f(e'), & \text{если } (f(e) - f(e')) < 0, \\ 0, & \text{в противном случае} \end{cases} \quad (4.55)$$

где $B_{cd}(c), B_{cd}(d)$ - множества нейронов в некоторой окрестности от нейронов c, d ;

$W_{cd}(x), \varpi_{cd}(x)$ – функции принадлежности утверждения «величина x мала».

Окончательно искомая функция имеет вид:

$$E(t) = \sum_{i \in \Gamma} H_t(i)X(i) + (1 - H_t(i))Y(i). \quad (4.56)$$

Минимум функции $E(t)$ является оптимальным порогом активизации нейронов. На рис. 4.25 приведен интерфейс программы вычисления оптимального порога активизации нейронов.

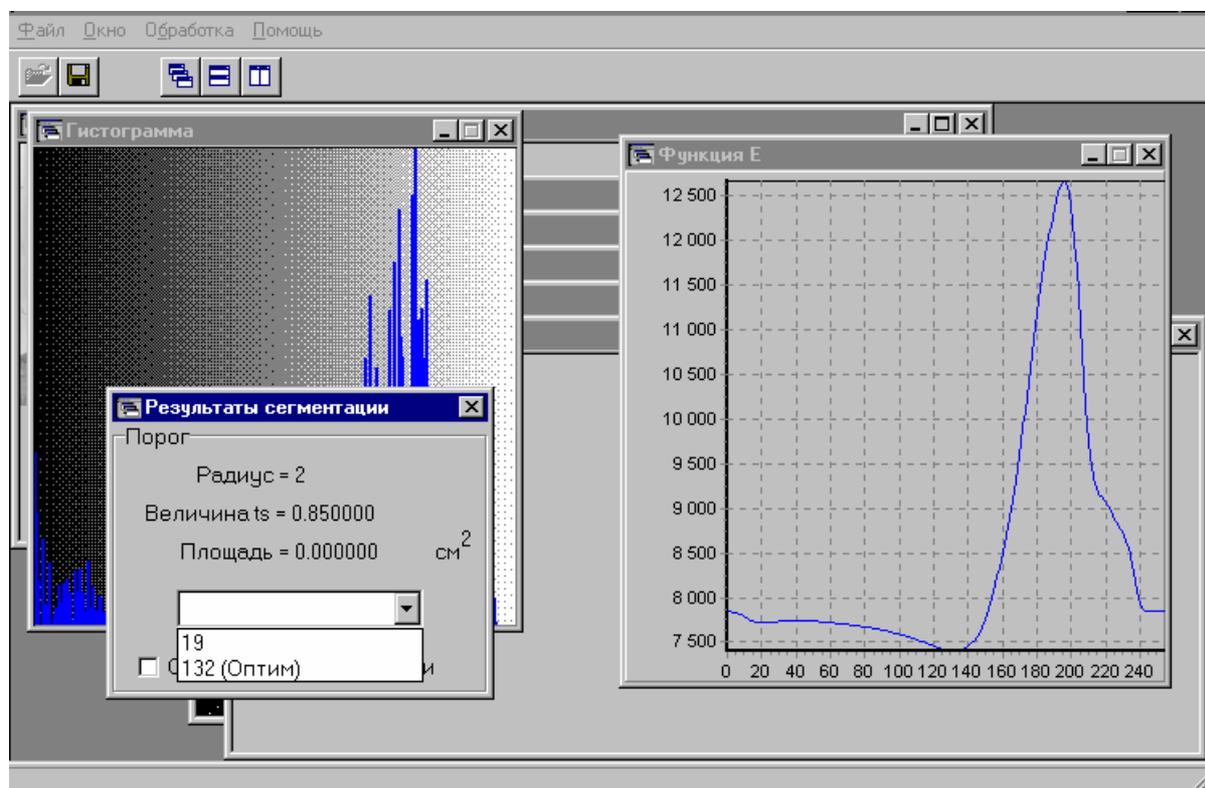


Рис 4.25. Определение оптимального порога активизации нейронов запоминающего слоя ассоциативного ЗУ

Емкость нейронного ассоциативного ЗУ зависит от размерности используемой нейронной сети. В настоящее время автором разработана компьютерная модель постоянного запоминающего устройства (рис. 4.25) на трехслойной нейронной сети с размерностью слоев 32×32 нейрона.

5. Поясните назначение основных элементов интерфейса компьютерной системы краниофациальной идентификации.
6. Какие факторы влияют на точность идентификации?
7. Как определяется расстояние Хэмминга?
8. Охарактеризуйте нейросетевой алгоритм защиты информации в системах связи.
9. Назовите методы решения задачи реконструкции динамических систем.
10. В чем заключаются особенности методики применения нейросетевых классификаторов для обработки данных физики высоких энергий?
11. Изобразите структурную схему нейронного постоянного запоминающего устройства.

Заключение

Подводя итог, можно заметить, что нейросетевые технологии находят все новые применения в практике принятия решений и управлении сложными организационно-техническими системами. Нейронные сети могут очень эффективно применяться для обнаружения сложных зависимостей, когда отсутствуют априорные знания об исследуемой системе или процессе. Нейронные сети также можно использовать везде, где обычно применялись линейные методы и алгоритмы и производилось оценивание при помощи статистических методов анализа, таких как регрессионный, кластерный, дискриминантный анализ, временные ряды.

Приведенные выше примеры показывают, что технологии нейронных сетей применимы во многих областях для решения практических задач. Кроме того, в некоторых задачах, таких как прогнозирование курса валюты, котировок или распознавания образов нейронные сети стали уже привычным инструментом. Нет сомнений, что применение новых технологий и в других областях является только вопросом времени.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Анил К. Джейн, Живанчанг Мао, Моуддин К.М.* Введение в искусственные нейронные сети //Открытые системы. – 1997. – № 4. – С. 17 – 24.
2. *Васильев В.И.* Распознающие системы. – Киев: Наук. думка, 1988. – 231 с.
3. *Галушкин А.И.* Синтез многослойных систем распознавания образов. – М.: Энергия, 1974. – 114 с.
4. *Галушкин А.И., Кирсанов Э.Ю.* Нейронные системы памяти: Учеб./ Под ред. В.К. Левина. – М.: Изд-во МАИ, 1991. – 180 с.
5. *Горбань А.Н.* Обучение нейронных сетей. – М.: СП ПараГраф, 1991. – 159 с.
6. *Горбань А.Н., Россиев Д.А.* Нейронные сети на персональном компьютере. – Новосибирск: Наука, 1996. – 184 с.
7. *Горбань А.Н., Дунин-Барковский В.Л* и др. Нейроинформатика. – Новосибирск: Наука, 1998. – 203 с.
8. *Горлов В.Н.* Моделирование систем ассоциативной памяти современных и перспективных ЭВМ: Учеб. пособие/ Владим. гос. ун-т. – Владимир, 1999. – 64 с.
9. *Горлов В.Н., Малафеев С.И., Краснов Ф.А.* Система автоматизированного распознавания видеоизображений на основе нейронной сети // Проектирование и технология электронных средств. – 2001. – № 2. – С. 31-39.
10. *Горлов В.Н., Малафеев С.И.* Применение многослойных нейронных сетей к решению задачи защиты информации // Проектирование и технология электронных средств. – 2002. – № 2. – С. 46 – 49.
11. *Дуда Р., Харт П.* Распознавание образов и анализ сцен. – М.: Мир, 1976. – 275 с.
12. *Змитрович А.И.* Интеллектуальные информационные системы. – Минск: НТООО ТерраСистемс, 1997. – 193 с.
13. * *Короткий С.* Нейронные сети: алгоритм обратного распространения // <http://www.neuropower.de/rus/books/index.html>.

* Указанные названия из сети Интернет

14. *Короткий С. Нейронные сети: обучение без учителя // [http://www. – neuropower.de/rus/books/index.html](http://www.neuropower.de/rus/books/index.html).
15. *Короткий С. Нейронные сети: основные положения// [http://www. – neuropower.de/rus/books/index.html](http://www.neuropower.de/rus/books/index.html).
16. *Короткий С. Нейронные сети Хопфилда и Хэмминга// [http://www. – neuropower.de/rus/books/index.html](http://www.neuropower.de/rus/books/index.html).
17. Круглов В.В., Борисов В.В., Харитонов Е.В. Нейронные сети: конфигурация, обучение, применение. – Смоленск: Изд-во Моск. энерг. ин-та в г. Смоленске, 1998. – 254 с.
18. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. – М.: Горячая линия Телеком, 2001. – 224 с.
19. Нейрокомпьютеры и интеллектуальные роботы / Под ред. Н.М. Амосова. – Киев: Наук. думка, 1991. – 198 с.
20. Огнев И.В., Борисов В.В. Ассоциативные среды. – М.: Радио и связь, 2000. – 310 с.
21. Перцептрон – система распознавания образов / Под ред. А.Г. Ивахненко. – Киев: Наук. думка, 1975. – 247 с.
22. Попов Э.В., Фоминых И.Б., Кисель Е.Б. и др. Статистические и динамические экспертные системы. – М.: Финансы и статистика, 1996. – 156 с.
23. Розенблатт Ф. Принципы нейродинамики: Перцептроны и теория механизмов мозга. – М.: Мир, 1965. – 480 с.
24. Соколов Е.Н., Вайткявичус Г.Г. Нейроинтеллект: от нейрона к нейрокомпьютеру. – М.: Наука, 1989. – 316 с.
25. *Сотник С. Курс лекций по предмету «Основы проектирования систем с искусственным интеллектом // <http://www.neuropower.de/rus/books/index.html>.
26. Куффнер С., Николс Дж. От нейрона к мозгу. – М.: Мир, 1979. – 157 с.
27. Уоссермен Ф. Нейрокомпьютерная техника. – М.: Мир, 1992. – 320 с.
28. Горлов В.Н. Нейросетевой алгоритм защиты информации в системах персонального радиовызова (пейджинговых системах) // Сб. тр. IV Междунар. науч.-техн. конф. «Перспективные технологии в средствах передачи информации». – Владимир: РОСТ, 2001. – с. 120-121.
29. Анищенко В.С., Павлов А.Н. и др. Реконструкция динамических систем в приложении к решению задачи защиты информации // Журнал технической физики. – 1998. – Т.68. – № 12. – С. 1 – 8.
30. Чилингарян А.А. Математические модели нейронных сетей как системы распознавания образов: Препр. ЕФИ-1350(45)-91. – Ереван. Ереван. физ. ин-т. – 1991. – 25 с.

ОГЛАВЛЕНИЕ

Предисловие.....	3
Глава 1. БИОЛОГИЧЕСКИЕ НЕЙРОННЫЕ СЕТИ.....	6
1.1. Структурная организация нейронных сетей	6
1.2. Организация сигнальных связей между нейронами.....	17
Контрольные вопросы и задания.....	19
Глава 2. МОДЕЛИРОВАНИЕ НЕЙРОННЫХ СЕТЕЙ	20
2.1. Структура и свойства искусственного нейрона.....	20
2.2. Классификация искусственных нейронных сетей.....	27
2.3. Алгоритмы обучения нейронных сетей.....	33
Контрольные вопросы и задания.....	57
Глава 3. МОДЕЛИРОВАНИЕ БИОЛОГИЧЕСКОЙ ПАМЯТИ	59
3.1. Организация биологической памяти на клеточном уровне.....	59
3.2. Ассоциативная память нейронных сетей.....	62
3.3. Модели ассоциативной памяти.....	65
Контрольные вопросы и задания.....	75
Глава 4. ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ	76
4.1. Нейрокомпьютерная система идентификации личности.....	76
4.2. Применение многослойных нейронных сетей к решению задачи защиты информации	90
4.3. Применение нейросетевых классификаторов для обработки данных физики высоких энергий	96
4.4. Нейросетевые устройства постоянной памяти	111
Контрольные вопросы и задания.....	120
Заключение	122
Библиографический список.....	123

Учебное издание

ГОРЛОВ Виктор Николаевич

ПРИКЛАДНЫЕ НЕЙРОКОМПЬЮТЕРНЫЕ СИСТЕМЫ

Учебное пособие

Редактор Р.С. Кузина

Корректор Е.В. Афанасьева

Компьютерная верстка Е.Г. Радченко

ЛР № 020275. Подписано в печать 17.11.03.

Формат 60×84/16. Бумага для множит. техники. Гарнитура Таймс.

Печать на ризографе. Усл. печ. л. 7,44. Уч.-изд. л. 7,64. Тираж 60 экз.

Заказ

Редакционно-издательский комплекс

Владимирского государственного университета.

600000, Владимир, ул. Горького, 87.