

2. ТЕОРИЯ НЕЙРОННЫХ СЕТЕЙ

2.1. Введение

2.2. Базовые понятия теории НС

2.3. Основные парадигмы НС

2.4. Заключение

2.1. Введение

Сеть нейронов, образующая человеческий мозг, представляет собой высокоэффективную комплексную, существенно-параллельную систему обработки информации. Она способна организовать свои нейроны таким образом, чтобы реализовать восприятие образа, его распознавание во много раз быстрее, чем эти задачи будут решены самыми современными компьютерами. Так распознавание знакомого лица происходит в мозге человека за 100-120 мс, в то время как компьютеру на это требуются минуты или даже часы. Сегодня, как и 40 лет назад, несомненно то, что мозг работает гораздо более эффективно и принципиально другим образом, чем любая вычислительная машина, созданная человеком. Именно этот факт в течении стольких лет побуждает и направляет работы ученых по воссозданию и исследованию *нейронных сетей* (НС).

Термин «нейронная сеть» является фактически биологическим термином, и поэтому нейронные сети должны в действительности называться Искусственными Нейронными Сетями (ИНС). Но не будем заострять на этом внимание, и, чтобы не путаться в терминах в дальнейшем, будем использовать общепринятый термин Нейронная Сеть. Реальная НС это собрание нейронов - крошечных ячеек, из которых состоит наш мозг. Сеть может состоять из нескольких миллиардов нейронов, связанных и взаимодействующих между собой различными методами. С помощью ИНС делается попытка воссоздания модели этих биологических структур, и в архитектуре и во взаимодействии. Но здесь имеется одна маленькая проблема: мы не знаем в точности, каким образом реальная НС работает. Архитектура реальной НС в корне изменяется от типа к типу, единственное, на что мы можем опереться – мы знаем каким образом устроена элементарная ячейка сети – *нейрон*. Подробно его строение будет рассмотрено ниже.

В отношении к применению сегодня НС в практике существуют много «за» и «против». К очевидным достоинствам НС можно отнести возможность применения их в тех областях, в которых традиционные методы не работают, например использование НС в системах, имеющих дело с постоянным притоком больших объемов данных разного рода (например, в радарных и сонарных системах). Многие типы НС биологически верны, то есть с их помощью можно также изучить мыслительные процессы, которые происходят в мозгу человека. Современные разработки в области НС приводят нас к мысли, что в скором будущем возможно будет их применение в сортировке и обработке объектов со скоростью превосходящей скорость любых современных компьютеров. Будущее в этом плане представляется довольно ярким, однако сегодня у НС имеется большое количество недостатков, и к сожалению они во многом пересекаются с недостатками возможностей вычислительных машин. Одним из очевидных достоинств НС является существенное *распараллеливание* вычислительных процессов, однако процесс эмуляции алгоритмов НС на современных *последовательных* компьютерах может быть существенно заторможен, так как ЭВМ может решать в определенный момент времени только одну задачу. Соответственно скорость обработки данных при помощи НС очень низка, и поэтому НС в настоящее время исключены из списка жизнеспособных решений данной проблемы.

В этой главе мы рассмотрим теоретические основы построения нейронных сетей, рассмотрим такие основные понятия как перцептрон, методы обучения НС, типы архитектур и другие вопросы, связанные с применением НС в решении вопросов обработки данных. Также попытаемся доказать превосходство методов НС в деле распознавания объектов, а также необходимость их использования в современной робототехнике.

2.1.1. Исторический обзор

Исследования в области ИНС пережили три периода активизации. Первый пик в 40-х годах обусловлен пионерской работой МакКаллока и Питтса [7], в которой была изложена идея построения автомата на основе пороговых элементов, подобных нервным клеткам, способного выполнять логические функции. Однако задача проектирования систем на основе пороговых элементов оказалась чрезвычайно трудной, и ее решение, найденное лишь спустя 20 лет, оказалось настолько сложным, что практически исключало возможность синтеза автоматов, содержащих более десятка нейронов. Поэтому уже первые попытки практической реализации таких автоматов были связаны с поиском методов их обучения по аналогии с нервной системой живых организмов.

Обучаемые системы на основе пороговых элементов получили название искусственных нейронных сетей. С разработкой первых ИНС связан второй период активизации, который возник в 60-х благодаря теореме сходимости перцептрона Розенблатта [8], разработанной им в 1959 году. К концу 60-х в США действовало несколько экспериментальных моделей ИНС. Первые крупные перцептроны на основе аналоговой и цифровой техники ("Адам-А" и "Адам-Д") за пределами США были созданы в 1969-71 гг. в Советском Союзе в одном из киевских НИИ [14]. Схема простейшего перцептрона Розенблатта изображена на рис.2.1. Он содержит три слоя пороговых элементов. Входные сигналы (стимулы), воздействуя на рецепторы (S-элементы), переводят их в возбужденное состояние. S-элементы случайным образом связаны с совокупностью ассоциативных нейронов (A-элементов). Выход A-элемента отличается от нуля только тогда, когда возбуждено достаточно большое число связанных с ним рецепторов. Реакции A-элементов поступают на входы эффекторов (R-элементов) через связи, вес которых изменяется при обучении. В эффекторах вычисляется постсинаптический потенциал - взвешенная сумма поступивших сигналов. Обычно в перцептроне для каждого запоминаемого образа выделяется один эффектор, и решение принимается по максимуму значения постсинаптического потенциала. Свойственная перцептрону Розенблатта неоднородность структуры (разделение на S-, A- и R-элементы) в более поздних моделях ИНС утрачивается. Работа Минского и Пейперта [9], указала ограниченные возможности простейшего перцептрона. Результаты Минского и Пейперта погасили энтузиазм большинства исследователей, особенно тех, кто работал в области вычислительных наук. Возникшее в исследованиях по нейронным сетям затишье продлилось почти 20 лет.




Рис.2.1

Возрождению интереса к ИНС способствовал ряд обстоятельств:

- трудности с реализацией логических систем искусственного интеллекта, создаваемых в рамках японского проекта ЭВМ 5-го поколения;
- появление принципиально новых идей в отношении организации памяти и обучения нейронных сетей;
- заметное отставание темпов роста производительности ЭВМ от стремительного увеличения потребности в высокопроизводительных вычислениях.

С начала 80-х годов ИНС вновь привлекли интерес исследователей, что связано с энергетическим подходом Хопфилда [10] и алгоритмом обратного распространения для обучения многослойного перцептрона (многослойные сети прямого распространения), впервые предложенного Вербосом и независимо разработанного рядом других авторов. Алгоритм получил известность благодаря Румельхарту в 1986 году [13].

С середины 80-х гг. непрерывно растет интерес к моделированию нейронных сетей. Их особенностью является параллельная работа, и поэтому моделирование таких сетей на ЭВМ, имеющих традиционную архитектуру, требует затрат большого количества времени. Для ускорения этого процесса в разных странах мира начали появляться специализированные устройства, получившие название нейрокомпьютеров. *Нейрокомпьютинг* - это научное направление, занимающееся разработкой вычислительных систем шестого поколения - нейрокомпьютеров, которые состоят из большого числа параллельно работающих простых вычислительных элементов (нейронов). Элементы связаны между собой, образуя нейронную сеть. Они выполняют единообразные вычислительные действия и не требуют внешнего управления. Большое число параллельно работающих вычислительных элементов обеспечивают высокое быстродействие. В настоящее время разработка нейрокомпьютеров ведется в большинстве промышленно развитых стран. Нейрокомпьютеры позволяют с высокой эффективностью решать целый ряд "интеллектуальных" задач. Сегодня разработками в этой области занимается более 300 компаний. Среди них такие гиганты как Intel , DEC , IBM , Motorola . Нейрокомпьютеры в системах управления динамическими объектами - это одна из самых перспективных, областей применения нейрокомпьютеров. По крайней мере, США и Финляндия ведут работы по использованию нейрокомпьютеров для управления химическими реакторами. В России этим не занимались, в частности, по причине морального устаревания существующих реакторов и нецелесообразности совершенствования их систем управления.

2.1.2. Биологические основы построения НС

К первым попыткам раскрыть секреты анатомической организации мозга можно отнести исследования Сантьяго Рамон-и-Кахаля (1911). Применяв метод окраски нейронов солями серебра, разработанный ранее Камилло Гольджи (серебро избирательно проникает в нейроны, но не пропитывает другие клетки мозга), Кахаль увидел, что мозг имеет клеточную архитектуру. Кроме нейронов в состав мозга входят разнообразные глиальные клетки, выполняющие опорные и участвующие в репарационных процессах. Кахаль описал *нейроны* как поляризованные клетки, которые получают сигналы сильно

разветвленными отростками, названными *аксонами* (рис.2.2). Окрашивание по Гольджи позволило выявить огромное разнообразие нейронов по форме тела, разветвленности дендритной части и длине аксона. Кахаль выявил различия между клетками с короткими аксонами, взаимодействующими с соседними нейронами, и клетками с длинными аксонами, проецирующимися в другие участки мозга.




Рис.2.2

Несмотря на различия в строении, все нейроны проводят информацию одинаково. Информация передается по аксонам в виде коротких электрических импульсов, так называемых потенциалов действия, амплитуда которых составляет около 100 мВ, а длительность 1 мс. Возникновение импульсов связывают с движением положительно заряженных ионов натрия через поверхностную клеточную мембрану из внеклеточной жидкости внутрь клетки, в ее цитоплазму. Концентрация натрия в межклеточном пространстве примерно в 10 раз больше его внутриклеточной концентрации. В состоянии покоя поддерживается трансмембранная разность потенциалов около -70 мВ. При этом ионы натрия проникают в клетку медленно, так как доступ туда для них ограничен свойствами мембраны. Физическая или химическая стимуляция, деполяризующая

мембрану, увеличивает ее проницаемость для ионов натрия. Поток натрия внутрь клетки еще сильнее деполяризует мембрану, делая ее еще более проницаемой.

Когда достигается некоторое критическое значение потенциала, называемое пороговым, положительная обратная связь приводит к регенеративным сдвигам, в результате которых знак разности потенциалов изменяется на противоположный, то есть внутреннее содержимое клетки становится заряженным положительно по отношению к внешней среде. Приблизительно через 1 мс проницаемость мембраны для натрия падает, и трансмембранный потенциал возвращается к своему значению в состоянии покоя – 70 мВ. После каждого такого «взрыва» нейрон остается на несколько миллисекунд рефрактным, то есть натриевая проницаемость мембраны в этот период не может изменяться. Это кладет предел частоте генерации импульсов – не более 200 раз в секунду. Хотя аксоны похожи на провода, импульсы они проводят иначе. Их кабельные характеристики неважные: сопротивление вдоль оси слишком велико, а мембранное сопротивление слишком мало. Положительный заряд рассеивается уже через 1-2 мм. Чтобы преодолевать расстояния, составляющие иногда несколько сантиметров, импульсы должны регенерироваться. Необходимость повторно усиливать ток ограничивает максимальную скорость распространения нервного импульса по аксону до 100 м / с.

Связи между нейронами опосредуются химическими передатчиками – *нейромедиаторами* – выделяющимися из окончаний отростков нейронов в синапсах. Когда потенциал действия достигает окончания аксона, молекулы медиатора выходят из внутриклеточных маленьких пузырьков, где они хранятся, в синаптическую щель – пространство шириной 20 нм между мембранами пресинаптической и постсинаптической клеток. Когда возбуждения достигает пика, начинается координированное выделение молекул нейромедиатора. Высвободившиеся молекулы нейромедиатора связываются с рецепторами в постсинаптической мембране, что изменяет ее проницаемость. Эффект будет возбуждающим, если изменение заряда приближает мембранный потенциал к порогу генерирования импульса. Каждый синапс дает лишь незначительный эффект на активность аксона нейрона. Чтобы установилась интенсивность выхода, каждый нейрон должен непрерывно интегрировать до 1000 синаптических входов. Еще в начале века нейрофизиологам стала ясна исключительно важная роль синапсов в обучении. Сигналы мозга, проходя через них, могут в разной степени усиливаться или ослабляться [15].

Кора головного мозга человека является протяженной, образованной нейронами поверхностью толщиной от 2 до 3 мм с площадью около 2200 см², что вдвое превышает площадь поверхности стандартной клавиатуры. Кора головного мозга содержит около 10¹¹ нейронов, что приблизительно равно числу звезд Млечного пути. Каждый нейрон связан с 10³ - 10⁴ другими нейронами. В целом мозг человека содержит приблизительно от 10¹⁴ до 10¹⁵ взаимосвязей. Обращает на себя внимание и тот факт, что мозг новорожденного и мозг взрослого человека содержат примерно одинаковое количество нейронов. Но только мозг взрослого человека отличается упорядоченностью межнейронных синаптических связей. По-видимому, обучение мозга и есть процесс изменения архитектуры нейронной сети, сопровождаемый настройкой синапсов.

2.1.3. Основные парадигмы структурного построения мозга

В дальнейших выкладках мы будем использовать некоторые основные положения структурного построения мозга, и поэтому приведем в данном подпункте две основные модели или парадигмы данной области:

- информационная структура внешнего сигнала первична и поэтому необходима для выработки кодированной мозговой структуры - *инструкционная теория*;
- перед лицом неизвестного будущего основным условием успешного приспособления является предсуществующая структурная организация мозга. Здесь первичным является структура мозга, а вторичным сигнал - *селективная теория*.

В нейрофизиологии ведутся активные исследования по структурной организации мозга. Накопился ряд экспериментальных фактов представляющих значительный интерес для технических приложений. В 80-х годах нейрофизиологи пришли к выводу, что основным организующим принципом мозга является модульное строение и распределенная обработка информации [17]. Наиболее выраженная модульная организация обнаружена в новой коре головного мозга, которая главным образом ответственна за мышление, речь и другие формы высшей нервной деятельности. Развитие новой коры происходило стремительным образом (в масштабах эволюции) по заключениям нейрофизиологов такой процесс был возможен только за счет многократного повторения модульной структуры. Экспериментальные исследования установили поразительное постоянство размеров нейронного модуля (примерно 110 нейронов), который получил название кортикальной колонки. Связи между колонками объединяют их в компактные группы (макроколонки) с сохранением определенного топологического порядка. Принцип топологического порядка сохраняется и на более высоких уровнях структурной организации. В целом нейронная сеть новой коры состоит из множества модульных элементов (примерно 600 млн. колонок), связанных между собой в «эшелонированные» параллельно - последовательные объединения.

Модульная организация мозга не противоречит обеим точкам зрения, но повторение топологической структуры и явно выраженный порядок в организации связей невозможно объяснить, исходя из парадигмы первичности сигнала над структурой мозга. Бесспорно, что структура мозга сложилось в результате онтогенеза и на первых этапах развития, первичность сигнала имела определяющее значение, однако в дальнейшем под действием естественной мутации процесс развивался подобно стохастической оптимизации: оптимальные структуры сохранялись в генетической памяти, а неудачные постепенно исчезали. Инструктивная модель для описания развитого мозга наталкивается на ряд логических трудностей. Так, например, в соответствии с этой моделью новые сенсорные события, в которых участвуют некоторые элементы предыдущих событий, должны содержать компоненты предыдущих структур или же закладывать совершенно новые структуры. В первом случае последовательно приобретаемый опыт потребует наличия механизма высшего порядка, чтобы отличать старые элементы от новых, а во втором случае будет велик риск истощения информационного потенциала системы. Инструктивная теория не создает основы таких проявлений высшего порядка как сознательное восприятие и творческое программирование будущих событий. В некотором смысле такая теория отдает мозг «на милость» окружающего мира.

Не отрицая в целом ценность инструктивной модели, которая нашла применение в технических приложениях, остановимся подробнее на селективной теории. Нейрофизиолог Дж. Эдельман [18], поддержавший в 1975 году эту теорию, выделяет следующие свойства селективных структур:

- 1) Вырожденность (терминология Эдельмана). Это свойство предполагает, что селективная структура обеспечивает более одного способа удовлетворительного распознавания данного входного сигнала. Иными словами должно быть несколько нейронных групп, функционально дублирующих распознавание, но различающихся системой признаков.

- 2) Избыточность. Это свойство предполагает наличие повторяющихся нейронных групп одинакового строения, т.е. работающих с одной и той же системой признаков.
- 3) Дистрибутивность. В селективной структуре нет никакой необходимости в том, чтобы выбранные изофункциональные группы были смежными, напротив рецепторные поля должны занимать некоторое общее положение в пространстве признаков, для того чтобы обеспечить распределенную обработку и надежность функционирования при локальных повреждениях.

2.2. Базовые понятия теории НС

В данной главе мы рассмотрим основные теоретические понятия, наименования и определения теории нейронных сетей, с тем, чтобы в дальнейшем не возвращаться больше к вопросам построения языка описания данного научного направления. А также попытаемся дать описание официальных формулировок и международных обозначений, для достижения унификации теоретических выкладок. В материале главы также будут даны некоторые наименования основных определений на английском языке, так как большинство научных изысканий в данной области производится в англоязычных странах, и поэтому основная часть материала публикуется именно на этом языке. Это будет сделано с целью облегчения продолжения работы в этой области на основе данного материала.

2.2.1. Предпосылки использования НС

В последние годы среди специалистов в области искусственного интеллекта наметился очевидный подъем интереса к новым нетрадиционным подходам в областях управления и распознавания объектов, то есть сформировавшихся вне рамок классической парадигмы, базирующейся на аппарате интегро-дифференциального исчисления. Трудно даже перечислить все те классификационные признаки, по которым эти подходы разнятся между собой, но одной из граней различия является то, то именно положено в основу концепции интеллектуализации – формализованные каким-либо образом знания человека, или свойственные ему приемы мышления, посредством которых он изучает окружающий мир и подчиняет его свои интересам.

К первой группе подходов можно отнести, например, жестко детерминированные экспертные системы, а также более гибкие системы на базе нечеткой логики (fuzzy logic). Второй подход реализуется в рамках эволюционных методов моделирования, под которыми мы подразумеваем генетические алгоритмы и нейронные сети [15].

В интеллектуальных системах на основе НС решаются проблемы распознавания образов, осуществления прогнозов, ассоциативных методов хранения информации, оптимизации и управления процессами. Наиболее традиционные системы искусственного интеллекта, реализованные на стандартных (не нейронных) алгоритмах не дают должной гибкости в решениях данных задач за пределами заданных при программировании условий. В современных компьютерах не решены проблемы приближения архитектуры и методов ведения расчетов к структуре человеческого мозга, и таким образом при решении нелинейных задач человеческий мозг имеет преимущество, так как в нем реализованы такие особенности как:

- адаптивность;
- способность к самообучению;
- распределенные методы представления информации;
- массовый параллелизм;
- устойчивость к ошибкам;
- гибкость в решении нелинейных проблем;
- практически полное отсутствие границ допустимой области решений.

В дальнейшем можно предположить, что решение приведенных выше проблем, если не полностью, то частично можно решить в интеллектуальных системах на основе НС.

2.2.2. Создание ИНС на основе реальных НС

Современные вычислительные машины во много раз превосходят человека в вопросах вычислительного характера, однако, человеческий мозг способен, например, хранить до 10 миллиардов бит информации в столь маленьком объеме, при этом обеспечивая столь быстрый доступ к хранящейся информации. Также человек превосходит компьютер в вопросе преобразования той лавины частот, которая приходит от различных органов чувств (частоты света, звуковые частоты и так далее), в конкретное представление о мире, то есть в вопросах распознавания объектов. Основной причиной в столь сильном различии в производительности компьютера и человека является различие архитектур построения нейронной системы человеческого мозга и логической бинарной системы современных компьютеров. В частности архитектура вычислительной машины оптимизирована для решения дискретных вычислительных задач, человеческий мозг же оптимизирован для решения нелинейных аналоговых задач, например, решения проблем восприятия.

Таким образом проблемы интеграции между компьютером и человеком могут решаться с помощью создания *искусственных нейронных сетей*, архитектура которых с одной стороны опирается на архитектуру реальных НС, а с другой стороны использует вычислительные возможности современных вычислительных машин.

Подобно реальной нейронной системе НС является вычислительной системой с огромным числом параллельно функционирующих простых процессоров с множеством связей. Модели НС в некоторой степени воспроизводят "организационные" принципы, свойственные мозгу человека. Моделирование структуры мозга с использованием НС может также способствовать лучшему пониманию биологических функций. Такие технологии производства, как VLSI (сверхвысокий уровень интеграции) и оптические аппаратные средства, делают возможным подобное моделирование. Глубокое изучение НС требует знания нейрофизиологии, науки о познании, психологии, физики (статистической механики), теории управления, теории вычислений, проблем искусственного интеллекта, статистики, математики, распознавания образов, компьютерного зрения, параллельных вычислений и аппаратных средств (цифровых/аналоговых/VLSI/оптических). С другой стороны, ИНС также стимулируют эти дисциплины, обеспечивая их новыми инструментами и представлениями. Этот симбиоз жизненно необходим для исследований по нейронным сетям.

Представим некоторые проблемы, решаемые в контексте НС.

- *Классификация образов.* Задача состоит в указании принадлежности входного образа (например, речевого сигнала или рукописного символа), представленного вектором признаков, одному или нескольким предварительно определенным классам. К известным приложениям относятся распознавание букв, распознавание речи, классификация сигнала электрокардиограммы, классификация клеток крови. В робототехнике одним из основных приложений является распознавание объектов из видеоинформации полученной от системы технического зрения.
- *Аппроксимация функций.* Предположим, что имеется обучающая выборка $((x_1, y_1), (x_2, y_2), \dots, (x_n, y_n))$ (пары данных вход-выход), которая генерируется неизвестной функцией (x) , искаженной шумом. Задача аппроксимации состоит в нахождении оценки неизвестной функции (x) . Аппроксимация функций необходима при решении многочисленных инженерных и научных задач моделирования.

- *Кластеризация/категоризация.* При решении задачи кластеризации, которая известна также как классификация образов "без учителя", отсутствует обучающая выборка с метками классов. *Кластеризация* - метод, применяющийся для анализа больших наборов данных заключающийся в разбиении всего множества на группы близкородственных элементов (кластеры). Кластеризация может быть использована для решения таких задач как обработка изображений, классификация, тематический анализ коллекций документов, построение репрезентативной выборки. Известны случаи применения кластеризации для извлечения знаний, сжатия данных и исследования свойств данных.
- *Предсказание/прогноз.* Пусть 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 . Задача состоит в предсказании значения $y(t_{n+1})$ в некоторый будущий момент времени t_{n+1} . Предсказание/прогноз имеют значительное влияние на принятие решений в бизнесе, науке и технике. Предсказание цен на фондовой бирже и прогноз погоды являются типичными приложениями техники предсказания/прогноза.
- *Ассоциативная память.* В модели вычислений фон Неймана, которая используется в современных вычислительных машинах, 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. Ассоциативная память, или память, адресуемая по содержанию, доступна по указанию заданного содержания. Содержимое памяти может быть вызвано даже по частичному входу или искаженному содержанию. Ассоциативная память чрезвычайно желательна при создании мультимедийных информационных баз данных.
- *Оптимизация.* Многочисленные проблемы в математике, статистике, технике, науке, медицине и экономике могут рассматриваться как проблемы оптимизации. Задачей алгоритма оптимизации является нахождение такого решения, которое удовлетворяет системе ограничений и максимизирует или минимизирует целевую функцию. Задача коммивояжера, относящаяся к классу NP-полных, является классическим примером задачи оптимизации.
- *Управление.* Рассмотрим динамическую систему, заданную совокупностью $\{u(t), y(t)\}$, где $u(t)$ является входным управляющим воздействием, а $y(t)$ - выходом системы в момент времени t . В системах управления с эталонной моделью целью управления является расчет такого входного воздействия $u(t)$, при котором система следует по желаемой траектории, диктуемой эталонной моделью. Примером является оптимальное управление приводами роботов.

2.2.3. Основные понятия

Существует большое количество определений ИНС, но наиболее емким представляется следующее определение ИНС как адаптивной машины, данное в [16]: *Искусственная нейронная сеть (neural network) – это существенно параллельно распределенный процессор, который обладает способностью к сохранению и репрезентации опытного знания. Она сходна с мозгом в 2-х аспектах:*

1. Знание приобретает сеть в процессе обучения;
2. Для сохранения знания используются силы межнейронных соединений, называемые также синаптическими весами.

Тремя основными понятиями в теории НС являются: нейрон, архитектура сети и понятие обучения. Рассмотрим определения данных понятий. В дальнейшем под понятием *нейрон* мы будем подразумевать понятие *искусственный нейрон*, для краткости изложения опуская слово «искусственный».

Впервые модель *нейрона* (neuron) была предложена МакКаллоком и Питтсом [7], которые предложили в его качестве использовать бинарный пороговый элемент. Этот математический нейрон вычисляет взвешенную сумму n входных сигналов $x_i, i = 1, 2 \dots n$, и формирует на выходе сигнал величины 1, если эта сумма превышает определенный порог u , и 0 - в противном случае. Часто удобно рассматривать u как весовой коэффициент, связанный с постоянным входом $x_0 = 1$. Положительные веса соответствуют возбуждающим связям, а отрицательные - тормозным. Математическое выражение данной концепции представлено в формуле (2.1):

$$S = \sum_{i=1}^n u_i x_i + u_0, \quad (2.1)$$

где u_0 - величина смещения.

Модель нейрона представлена на рис.2.3.




Рис.2.3

Традиционно активационная функция имеет ступенчатый вид, то есть сигнал на выходе нейрона y появляется лишь тогда, когда суммарное входное воздействие превышает некоторое критическое значение. Приведем 3 основных типа активационных функций:

$$f(s) = \begin{cases} a, & \text{если } s > a \\ s, & \text{если } -a \leq s \leq a \\ -a, & \text{если } s < -a \end{cases} \quad \text{-линейная,}$$

$$f(s) = \frac{1}{1 + e^{-s}} \quad \text{-сигмоидальная,}$$

$$f(s) = e^{-\frac{s^2}{\sigma^2}} \quad \text{-радиально-симметричная.}$$

МакКаллок и Питтс доказали, что при соответствующим образом подобранных весах совокупность параллельно функционирующих нейронов подобного типа способна выполнять универсальные вычисления. Здесь наблюдается определенная аналогия с биологическим нейроном: передачу сигнала и взаимосвязи имитируют аксоны и дендриты, веса связей соответствуют синапсам, а пороговая функция отражает активность сомы.

С точки зрения архитектуры НС может рассматриваться как направленный граф со взвешенными связями, в котором искусственные нейроны являются узлами. По архитектуре связей НС могут быть сгруппированы в два класса (рис. 2.4): сети прямого распространения, в которых графы не имеют петель, и рекуррентные сети, или сети с обратными связями. В наиболее распространенном семействе сетей первого класса, называемых *многослойным перцептроном* (multi layer perceptron), нейроны расположены слоями и имеют однонаправленные связи между слоями. На рис. 2.4 представлены типовые сети каждого класса. Сети прямого распространения являются статическими в том смысле, что на заданный вход они вырабатывают одну совокупность выходных значений, не зависящих от предыдущего состояния сети. Рекуррентные сети являются динамическими, так как в силу обратных связей в них модифицируются входы нейронов, что приводит к изменению состояния сети.

Способность к обучению является фундаментальным свойством мозга. В контексте ИНС процесс обучения имеет следующее определение.

Обучение НС - настройка архитектуры сети и весов связей для эффективного выполнения специальной задачи.

Обычно нейронная сеть должна настроить веса связей по имеющейся обучающей выборке. Функционирование сети улучшается по мере итеративной настройки весовых коэффициентов. Свойство сети обучаться на примерах делает их более привлекательными по сравнению с системами, которые следуют определенной системе правил функционирования, сформулированной экспертами. Для конструирования процесса обучения, прежде всего, необходимо иметь модель внешней среды, в которой функционирует нейронная сеть - знать доступную для сети информацию. Эта модель определяет парадигму обучения [19]. Во-вторых, необходимо понять, как модифицировать весовые параметры сети - какие правила обучения управляют процессом настройки. Алгоритм обучения означает процедуру, в которой используются правила обучения для настройки весов.

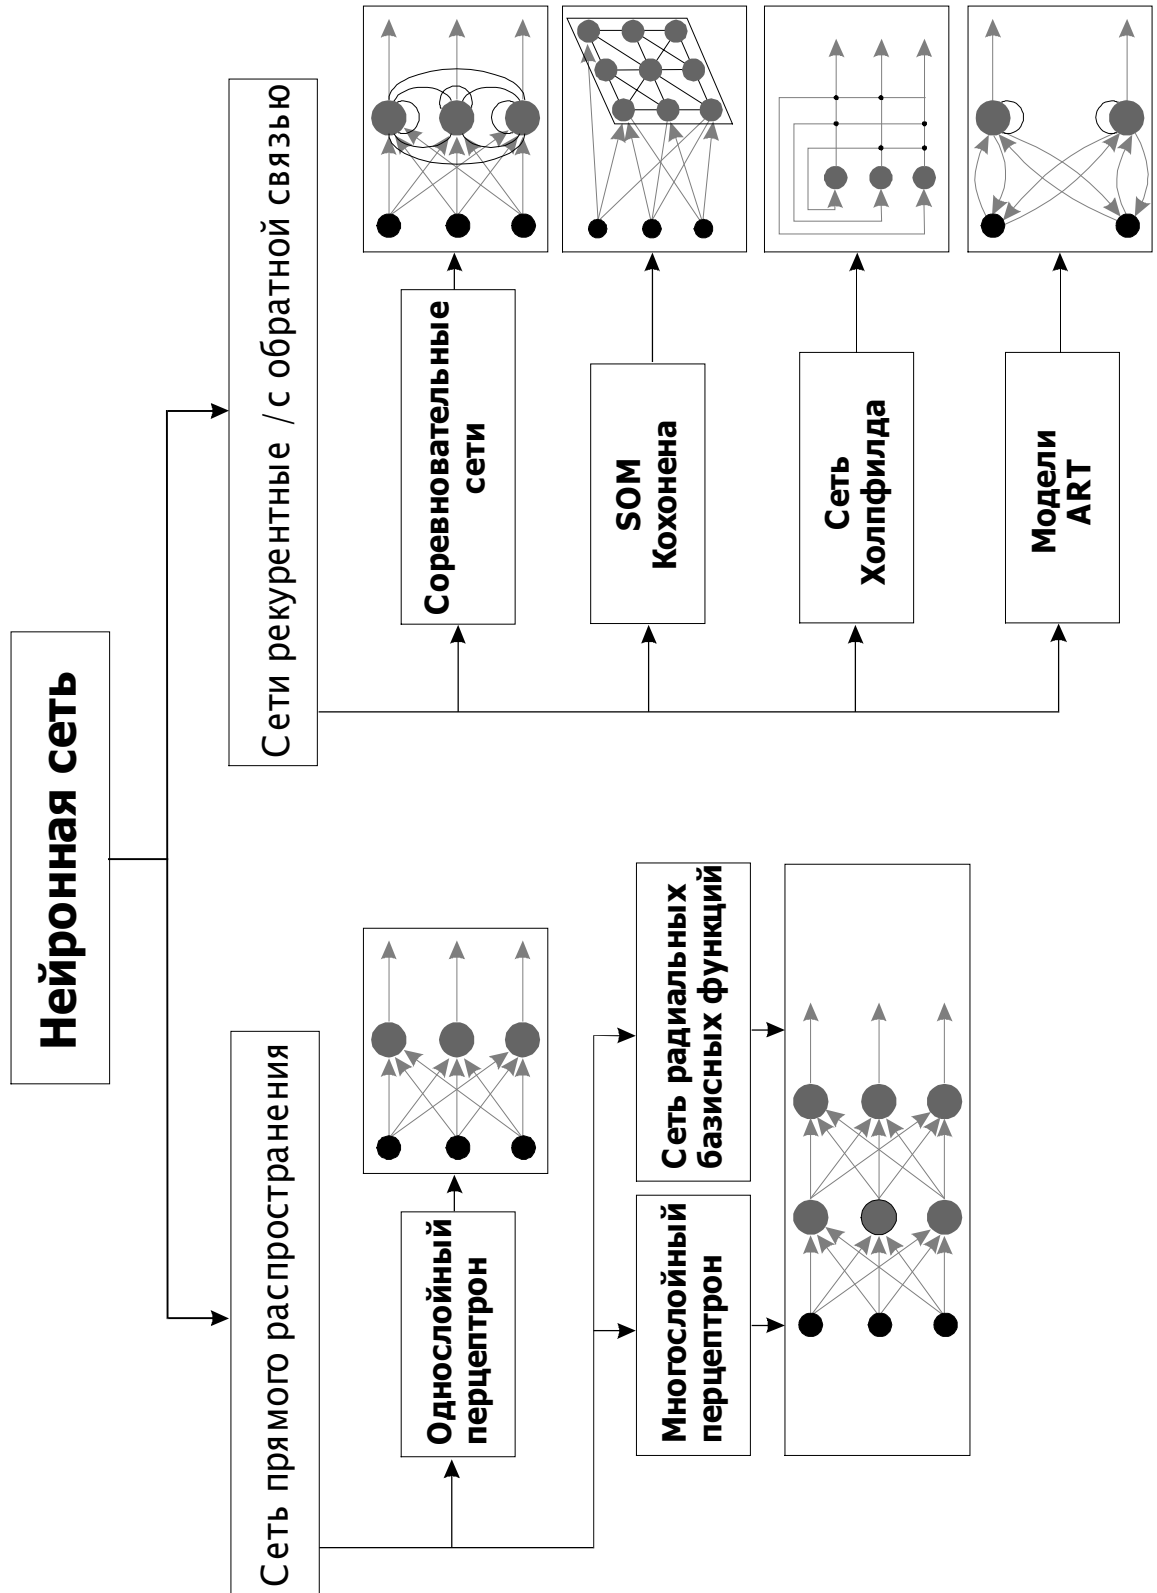


Рис.2.4

2.3. Основные парадигмы НС

В данной главе мы более подробно рассмотрим вопросы из теории НС, кратко рассмотренные в предыдущих главах. Эта глава содержит в себе довольно большое количество теоретических данных, и является попыткой охватить то огромное количество материала, который был накоплен в данной области за последние годы. Так как объем изложения сильно ограничен, то для более полного ознакомления с интересующими вас вопросами в данной области я посоветую обратиться к профессиональным источникам, приведенным в списке литературы.

2.3.1. Категоризация парадигм

Для упрощения изложения и категоризации приведенного в дальнейшем описания, перед непосредственным описанием основных парадигм НС приведем их краткую классификацию, сведенную в таблицу 2.1.

Табл.2.1

Название нейропарадигмы	Авторы	Год разработки	Области применения
Однослойный перцептрон (Single layer perceptron)	R. Rosenblatt	1959	Распознавание образов, классификация/категоризация
Обратное распространение ошибки (Back Propagation)	R. Rosenblatt, M. Minsky, S. Papert	1960-е	Распознавание образов, классификация, прогнозирование
Встречное распространение (Counter Propagation)	R. Hecht-Nielsen	1986	Распознавание образов, восстановление образов (ассоциативная память), сжатие данных
Входная звезда (Instar Network)	S. Grossberg	1974	Распознавание образов
Выходная звезда (Outstar Network)	S. Grossberg	1974	Распознавание образов
Искусственный резонанс-1 (ART-1 Network)	S. Grossberg, G. Carpenter	1986	Распознавание образов, кластерный анализ
Сеть Хопфилда (Hopfield Network)	J.J. Hopfield	1982	Поиск и восстановление данных по их фрагментам
Сеть Хэмминга (Hamming Network)	R. W. Hamming	1987	Распознавание образов, классификация, ассоциативная память, надежная передача сигналов в условиях помех
Сеть Кохонена (Kohonen Network)	T. Kohonen	1984	Кластерный анализ, распознавание образов, классификация
Сеть поиска максимума (MAXNET)	R.P. Lippman	1987	Совместно с сетью Хемминга, в составе НС систем распознавания образов
Сеть поиска максимума с прямыми связями (Feed-Forward MAXNET)	R.P. Lippman	1987	Совместно с сетью Хемминга, в составе НС систем распознавания образов
Двунаправленная автоассоциативная память (BAM Network)	B. Kosko	Вторая половина 80-х	Ассоциативная память, распознавание образов
Обучение Больцмана (Boltzman machine)	J. Hinton, T. Sejnowsky, H. Szu	1985	Распознавание изображений, сигналов радара, сонара
Классификатор Гаусса (Neural Gaussian Classifier)	R.P. Lippman	1987	Распознавание образов, классификация
Генетические алгоритмы (Genetic training algorithm)	J. Holland, D. Goldberg	1975 1988	Обучение НС, распознавание сигналов сонаров

2.3.2. Однослойный перцептрон

Однослойный перцептрон является базовым понятием в теории НС, но однако до сих пор не существует одного отдельного определения этого понятия. В настоящее время имеется большое количество алгоритмов, базирующихся на перцептронах, но очень часто бывает, что эти алгоритмы обладают довольно малым количеством схожих черт. Основной областью применения однослойных перцептронов является распознавание простейших образов.

Структура однослойного перцептрона очень проста. Имеется определенное количество входов $X_1 \dots X_N$, вес каждого из которых определяется весовой функцией $W_1 \dots W_N$. Веса входных сигналов также называют синаптическими весами, так как они реализуют функцию аналогичную функции синапсов в реальной НС. Функцией отдельного перцептрона, схема которого представлена на рис.2.5, является вычисление взвешенной суммы элементов входного сигнала, вычитая при этом значение смещения b , и пропуск результата через жесткую пороговую функцию, выход которой равен +1 или -1. В зависимости от значения выходного сигнала принимается решение: «+1» - входной сигнал принадлежит классу А, «-1» - входной сигнал принадлежит классу В. График передаточной функции порогового элемента изображен на рис. 2.7. Схема решающих областей, созданных в пространстве входных сигналов, для случая, когда размерность входного сигнала равна 2, показана на рис.2.6. В данном случае разделяющая поверхность представляет собой прямую на плоскости. Входные сигналы над

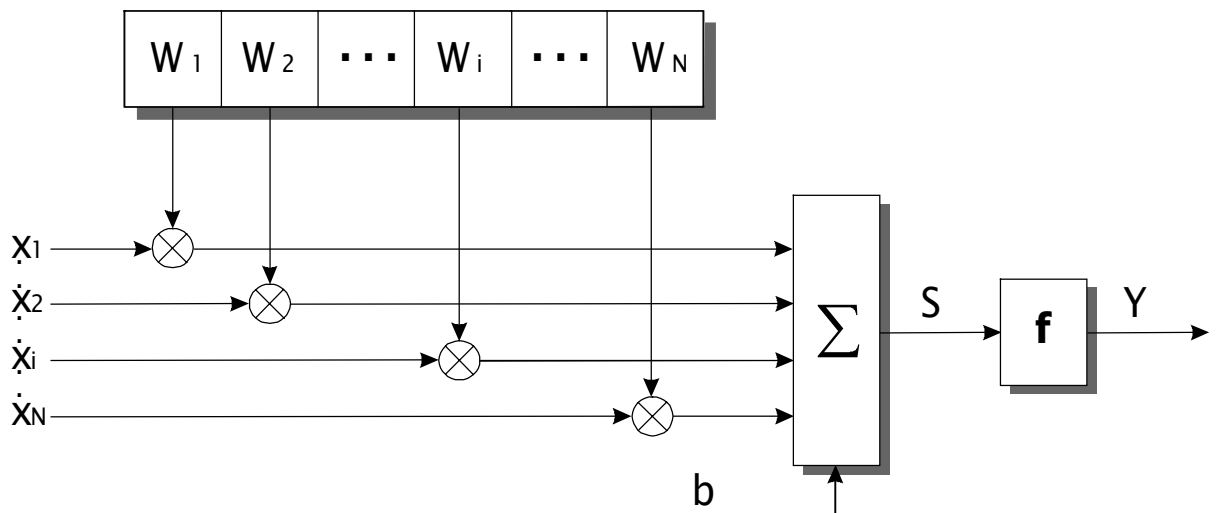


Рис.2.5




Рис.2.6




Рис.2.7

разделяющей линией относятся к классу А, под линией - к классу В. Уравнение, задающее разделяющую прямую, зависит от значений синаптических весов и смещения.

Алгоритм обучения однослойного перцептрона основан на изменении коэффициентов передачи синаптических весов, для более эффективного выполнения определенной задачи вследствие «ослабления» весового характера одних входов перцептрона и «усиления» других. Рассмотрим алгоритм обучения однослойного перцептрона более подробно с целью выяснения алгоритма программной реализации данного процесса.

1. *Инициализация синаптических весов и смещения:*

Значения синаптических весов $W_i(0)$ и смещение нейрона b устанавливаются равными некоторым малым случайным числам, где $W_i(t)$ – вес связи от i -го элемента входного сигнала ($0 \leq i \leq N$) к нейрону в момент времени t .

2. *Предъявление сети нового входного и желаемого выходного сигналов:*

Входной сигнал $X=(X_0, X_1, \dots, X_{N-1})$ предъявляется нейрону вместе с желаемым выходным сигналом d .

3. *Вычисление выходного сигнала нейрона:*

$$y(t) = f\left(\sum_{i=0}^{N-1} W_i(t) X_i(t) - b\right) \quad (2.2)$$

4. *Адаптация (настройка) значений весов:*

$$W_i(t+1) = W_i(t) + r[d(t) - y(t)]X_i(t), 0 \leq i \leq N-1 \quad (2.3)$$

$$d(t) = \begin{cases} +1, & \text{если } A \\ -1, & \text{если } B \end{cases}$$

где r – шаг обучения (должен быть меньше 1),

$d(t)$ - желаемый выходной сигнал.

Если сеть принимает правильное решение, то синаптические веса не модифицируются.

5. *Переход к шагу 2.*

При программной реализации данного алгоритма размерности входа и выхода ограничены только возможностями вычислительной машины, на которой производится моделирование НС. При аппаратной реализации – технологическими возможностями. Типы входных сигналов могут быть бинарными (дискретными) или аналоговыми (непрерывными). Емкость сети на базе однослойного перцептрона совпадает с количеством нейронов.

Очевидными преимуществами НС на базе однослойного перцептрона в системах распознавания изображения являются простота программной и аппаратной реализации, а также простота и высокое быстродействие алгоритма обучения. Однако явным недостатком такой НС, как видно из рис. 2.6, является примитивность разделяющих поверхностей, что дает возможность решать только самые простые задачи распознавания. Многослойные перцептроны дают возможность строить более сложные разделяющие поверхности и поэтому имеют более широкое применение при решении задач распознавания.

изображения. Примеры архитектур многослойных НС и вид разделяющей прямой при неизменном входном изображении приведены на рис.2.9.

Структура сети	Типы классифицируемых регионов	Классификация по операции XOR	Заполнение классификационного региона	Конечный вид классификационных регионов
	Два региона отделенных окружностью			
	Открытые выпуклые либо закрытые выпуклые регионы			
	Регионы произвольной формы			

Рис.2.9

Как уже отмечалось выше, применение многослойных НС на практике стало возможным благодаря разработке эффективного метода их обучения. Однако на первый взгляд метод обратного распространения представляет собой довольно сложный для понимания и программирования алгоритм. Чтобы наиболее наглядным образом объяснить суть данного метода ненадолго вернемся к однослойному перцептрон.

В однослойной НС каждый нейрон регулирует его веса согласно тому, насколько ожидаемый результат на его выходе совпадает с желаемым результатом, что математически может быть выражено через формулу (2.4), называемую *правилом дельты перцептрона* :

$$\Delta W_i = X_i \delta, \quad (2.4)$$

где $\delta = (\text{желаемый выход}) - (\text{реальный выход})$.




Рис.2.10

Но это правило не может быть использовано в случае расширения сети до нескольких слоев, которое требуется для решения нелинейных задач, так как при настройке одного весового коэффициента внутри сети мы должны учесть, какое влияние это окажет на работу всей сети в целом. Чтобы это сделать, мы должны учесть производную функции ошибки относительно изменяемого веса. Однако на данном шаге возникает проблема неудовлетворения функции перцептрона условиям непрерывности и дифференцируемости на всем диапазоне определения. Поэтому наиболее популярными альтернативными функциями в данном случае являются сигмоидальные функции. Вид

математического выражения наиболее простой сигмоидальной функции представлен в формуле (2.5), а ее график изображен на рис. 2.10.

$$f(s) = \frac{1}{1 - e^{-s}}, \quad (2.5)$$

Как видно из рисунка график функции пролегает в диапазоне от 0 до 1 по оси Y и от -5 до +5 по оси X, а также является непрерывным и легко дифференцируемым. Таким образом формула вычисления весовой функции для (2.6) имеет вид:

$$\Delta W_i = \frac{\eta}{P} \sum_{p=1}^P X_{ip} \delta_p. \quad (2.6)$$

Это весьма сложный вид формулы, и при определенном приближении ее можно несколько упростить:

$$\Delta W_i = \eta X_i \delta, \quad (2.7)$$

$$\text{где } \delta = Y_p(1 - Y_p)(d_p - Y_p). \quad (2.8)$$

Теперь мы получили обобщенную формулу, которая используется всецело в многослойной НС, однако мы не выяснили каким образом происходит расчет ошибки в скрытых слоях. Скрытые слои НС регулируются различными значениями δ , и мы должны знать эффект на выходе нейрона скрытого слоя в зависимости от изменения веса. Поэтому мы должны знать производную функции ошибки относительно изменяемого веса. Опустим вывод математического выражения правила дельты для данного случая, в случае надобности за более подробным описанием можно обратиться к специальной литературе. Доказано, что для нейрона q в скрытом слое p правило дельты будет выражено следующим образом:

$$\delta_p(q) = X_p(q)[1 - X_p(q)] \sum W_{p+1}(q, i) \delta_{p+1}(i). \quad (2.9)$$

Таким образом именно δ_{p+1} член формулы определяет понятие «обратный» в названии метода – обратное распространение. Каждое значение дельта δ для скрытого слоя определяется предыдущим его значением, рассчитанным ранее. То есть для, например, 3-хслойной сети дельта выходного слоя будет рассчитываться по формуле (2.8), полученное значение будет использоваться для расчета дельты скрытого слоя по формуле (2.9). Отсюда название метода «обратное распространение» означает распространение ошибки от выходного слоя назад через сеть.

Представим еще несколько вариантов сигмоидальных функций, которые применяются в настоящее время в качестве передаточных функций нейронов:

1. Однопараметрические:

- Функция Ферми (экспоненциальная сигмоида):

$$f(s) = \frac{1}{1 + e^{2s}}, \quad (2.10)$$

где s – выход сумматора нейрона.

- Рациональная сигмоида:

$$f(s) = \frac{s}{|s| + \alpha}. \quad (2.11)$$

- Гиперболический тангенс:

$$f(s) = th \frac{s}{\alpha} = \frac{e^{\frac{s}{\alpha}} - e^{-\frac{s}{\alpha}}}{e^{\frac{s}{\alpha}} + e^{-\frac{s}{\alpha}}}. \quad (2.12)$$

2. Многопараметрические:

$$f(s) = \rho_1 \frac{s}{s + \rho_2} + \rho_3. \quad (2.13)$$

В однопараметрических функциях значение функции зависит от аргумента и только от одного варьируемого параметра, в многопараметрических – параметров может быть несколько. Наиболее эффективной передаточной функцией является рациональная сигмоида. Для вычисления гиперболического тангенса требуется больше всего тактов работы процессора.

Для облегчения программирования метода обратного распространения ошибки приведем краткий алгоритм его программной реализации.

1. *Инициализация сети.*

Весовым коэффициентам и смещениям сети присваиваются малые случайные значения из диапазонов и соответственно.

2. *Определение элемента обучающей выборки.*

Текущие входы (X_0, X_1, \dots, X_{N-1}), должны различаться для всех элементов обучающей выборки. При использовании многослойного персептрона в качестве классификатора желаемый выходной сигнал (D_0, D_1, \dots, D_{N-1}) состоит из нулей за исключением одного единичного элемента, соответствующего классу, к которому принадлежит текущий входной сигнал.

3. *Вычисление текущего выходного сигнала.*

Текущий выходной сигнал определяется в соответствии с традиционной схемой функционирования многослойной нейронной сети.

4. *Настройка синаптических весов.*

Синаптические веса настраиваются в соответствии с правилами метода обратного распространения, начиная с выходных нейронов сети, а затем проходя сеть в обратном направлении до первого слоя.

Существует большое количество модификаций алгоритма обратного распространения, разработанных в последние десять лет исследований в данной области. Модификации связаны с использованием различных функций ошибки, процедур определения направления и величины шага, рассмотрим некоторые из них.

Различные виды функций ошибок:

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

Процедуры определения величины шага на каждой итерации:

- дихотомия;
- инерционные соотношения;
- отжиг.

Процедуры определения направления шага:

- с использованием матрицы производных второго порядка (метод Ньютона и др.);
- с использованием направлений на нескольких шагах.

В качестве недостатков метода обратного распространения стоит упомянуть о низкой скорости обучения вследствие того, что на каждом шаге итерации происходят изменения значений параметров сети, улучшающие работу лишь с одним примером обучающей выборки. Классический метод обратного распространения относится к методам с линейной сходимостью, и для увеличения скорости сходимости необходимо использовать матрицы вторых производных функции ошибки.

2.3.4. Входная звезда

Конфигурация «входная звезда» является фрагментом НС, впервые предложенная и изученная Гроссбергом в 1974 году, применяется в сетях искусственного резонанса (ART) и сетях прямого распространения.

Входная звезда (см. рис. 2.11) состоит из нейронов, каждый из которых суммирует значения его взвешенных входов согласно обычному правилу. Сами входы в свою очередь получены из слоя НС, вычисленного по принципу «победитель получает все», то есть только победивший нейрон – Y_j - имеет право на подачу своего выходного сигнала на следующий слой сети. Подобного рода организация в данном случае подчинена правилу обучения Кохонена, выраженного формулой:

$$[\Delta]W_{ij} = k(x_i - W_{ij})Y_j, \quad (2.14)$$

где для $k < 1$ выходной вектор становится похожим на входной вектор нейрона (то есть точки отсчета и направления векторов близко равны).

Частным случаем является равенство $k = 1$, когда входной и выходной вектора полностью совпадают.




Рис. 2.11

В процессе тренировки входной звезды она обучается реагировать только на определенный входной вектор X_i и ни на какой другой. Это обучение реализуется путем настройки весов таким образом, чтобы они соответствовали входному вектору. Выход звезды определяется как взвешенная сумма ее входов. С другой точки зрения, выход можно рассматривать как свертку входного вектора с весовым вектором. Следовательно, нейрон должен реагировать наиболее сильно на входной образ, которому был обучен. Процесс обучения выражается следующей формулой, выраженной из правила обучения Кохонена:

$$W_i(t+1) = W_i(t) + a[x_i - W_i(t)], \quad (2.15)$$

где W_i – вес входа X_i ,

a – нормирующий коэффициент обучения, который имеет начальное значение 0,1 и постепенно уменьшается в процессе обучения.

После завершения обучения предъявление входного вектора X будет активизировать обученный входной нейрон. Хорошо обученная входная звезда будет реагировать не

только на определенный вектор, но и на незначительные изменения этого вектора. Таким образом звезда будет проявлять способность к обобщению. Это достигается постепенной настройкой нейронных весов при предъявлении в процессе обучения векторов, представляющих вариации исходного входного вектора. Веса настраиваются таким образом, чтобы усреднить величины обучающих векторов, и нейроны получают способность реагировать на любой вектор этого класса.

2.3.5. Выходная звезда

Конфигурация «выходная звезда» является фрагментом НС, также впервые предложенная и изученная Гроссбергом в 1974 году. В настоящий момент данная конфигурация, обычно совместно с конфигурацией «входная звезда» применяется в сетях искусственного резонанса (ART), а также в сетях прямого распространения.




Рис.2.12

Выходная звезда состоит из нейронов, которые конвертируют взвешенную сумму входных сигналов X_i (в которых только один из битов равен 1, остальные 0) в распознанное выходное изображение. При этом нейрон сам управляет группой весов (см. рис. 2.12).

Отличие входной звезды от выходной заключается в том, что в то время как входная звезда возбуждается при предъявлении определенного входного вектора, выходная звезда имеет дополнительную функцию: она вырабатывает требуемый возбуждающий сигнал для других нейронов всякий раз, когда возбуждается.

В процессе обучения нейрона выходной звезды, его веса настраиваются в соответствии с требуемым целевым вектором. Процесс обучения выражается следующей формулой:

$$W_i(t+1) = W_i(t) + b[y_i - W_i(t)], \quad (2.16)$$

где b - нормирующий коэффициент обучения, который в начале приблизительно равен единице и постепенно уменьшается до нуля в процессе обучения.

Как и в случае входной звезды, веса выходной звезды постепенно настраиваются на множество векторов, представляющие собой вариации идеального (исходного) вектора. В этом случае выходной сигнал нейронов представляет собой статистическую характеристику обучающего набора.

Преимуществом применения выходной звезды является то, что она хорошо моделирует некоторые функции реальных НС. Гроссберг рассматривал выходные звезды как модели отдельных участков биологического мозга. Ее основным недостатком же

является реализация каждой выходной звездой в отдельности слишком простой функции, и следовательно вычислительные возможности сетей, основанных на выходных звездах ограничены.

Наилучшим видом применения выходных звезд может быть сеть, состоящая из комбинации входных и выходных звезд, которую в настоящий момент чаще всего используют в системах распознавания объектов, в случае низкой помехозащищенности входного изображения.

2.3.6. Сеть Хопфилда

Биофизик Джон Хопфилд работал в области организации ассоциативной памяти, начиная с 1974 года. Он является автором энергетического подхода к организации НС как динамической системы, рассеивающей энергию взаимодействуя с окружающей средой. Хопфилд рассматривал электрохимические явления, возникающие в результате взаимодействия между нейронами в сети. Им было предложено, что каждая физическая система, чей энергетический уровень зависит от суммы уровней каждого элемента данной системы может быть представлена как динамическая память с автогенерацией адресов (ассоциативная память). Кроме того, физическая система может рассматриваться как память в случае, если энергетический уровень каждого ее элемента потенциально зависит от уровня элементов, преобладающих в этой системе и имеющих более устойчивое состояние. Хопфилд рассматривал две модели сети в зависимости от типа входов и выходов нейрона, к которому происходит обращение: дискретные и непрерывные. Первая модель является существенно упрощенной, так как нейрон принимает на входе бинарный сигнал и выдает также бинарный сигнал. Для второй модели Хопфилд попытался создать наиболее вероятную модель биологического функционирования нейрона, в которой входной и выходной сигнал являются непрерывными. Модели, созданные Хопфилдом также могут применяться не только для организации ассоциативной памяти, но также для классификации/категоризации и решения некоторых задач оптимизации.

Одна из первых предложенных моделей сети Хопфилда используется как ассоциативная память. Исходными данными для расчета значений синаптических весов




Рис.2.13

сети являются векторы - образцы классов. Сеть функционирует циклически. Выход каждого из нейронов подается на входы всех остальных нейронов (рис.2.13). Нейроны сети имеют жесткие пороговые функции. Итерации сети завершаются после того, как выходные сигналы нейронов перестают меняться. Передаточная функция сети Хопфилда изображена на рис.2.14.




Рис.2.14

Емкость сети ограничена количеством нейронов, из которых она состоит, то есть сеть, содержащая N нейронов, может запомнить не более $M = 0,15 * N$ образов. При этом запоминаемые образы не должны быть полностью коррелированы, мерой корреляции при этом может служить формула (2.17):

$$K = \sum_{j,k}^M \sum_{i=1}^N x_i^j x_i^k, j \neq k, \quad (2.17)$$

где N – размерность входного сигнала,
 M – количество векторов-образцов,
 x_i^j - i -й элемент j -го вектора-столбца.

Формирование синаптических весов сети реализуется по формуле:

$$w_{i,j} = \begin{cases} \sum_{s=1}^M x_i^s x_j^s, i \neq j \\ 0, i = j \end{cases}, \quad (2.18)$$

$$1 \leq i, j \leq N$$

где $w_{i,j}$ – i -й синаптический вес j -го нейрона.

Функционирование сети производится в соответствии с формулой:

$$y_j(0) = x_j, 1 \leq j \leq N$$

$$y_j(t+1) = f\left(\sum_{i=1}^N w_{i,j} y_i(t)\right), 1 \leq j \leq N \quad (2.19)$$

где y_j – выход j -го нейрона.

Для данной формулы верно то, что функционирование сети прекращается в случае выполнения условия :

$$y_j(T) = y_j(T-1). \quad (2.20)$$

Таким образом суммарный выходной сигнал сети будет равен:

$$x_j' = y_j(T). \quad (2.21)$$

В данной сети одним из основных параметров будет изменение энергетической функции сети, в данном случае ее падение:

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{i,j} x_i x_j. \quad (2.22)$$

Одним из основных недостатков сети является ее малая емкость, полезное значение которой также уменьшается в два раза вследствие того, что наряду с запомненными образами в сети хранятся и их негативы. Возможность применения сети в задачах распознавания образов также ограничено тем, что размерность ее входных сигналов должна совпадать с размерностью выходных. Также недостатком сети можно считать квадратичный рост числа синапсов в зависимости от увеличения размерности входного сигнала.

Для увеличения емкости сети и увеличения ее качества в задаче распознавания образов используют мультипликативные нейроны. Сети, состоящие из таких нейронов, называются сетями высших порядков.

2.3.7. Сеть Хемминга

Расстояние Хемминга между двумя бинарными векторами одинаковой длины - это число несовпадающих бит в этих векторах. Нейронная сеть, которая реализует параллельное вычисление расстояний Хемминга от входного вектора до нескольких векторов-образцов, носит название сети Хемминга.

НС Хемминга – это двухслойная прямонаправленная сеть (см. рис. 2.15), способная распознавать объект из изображения с шумами, заложенный в нее на стадии обучения сети.

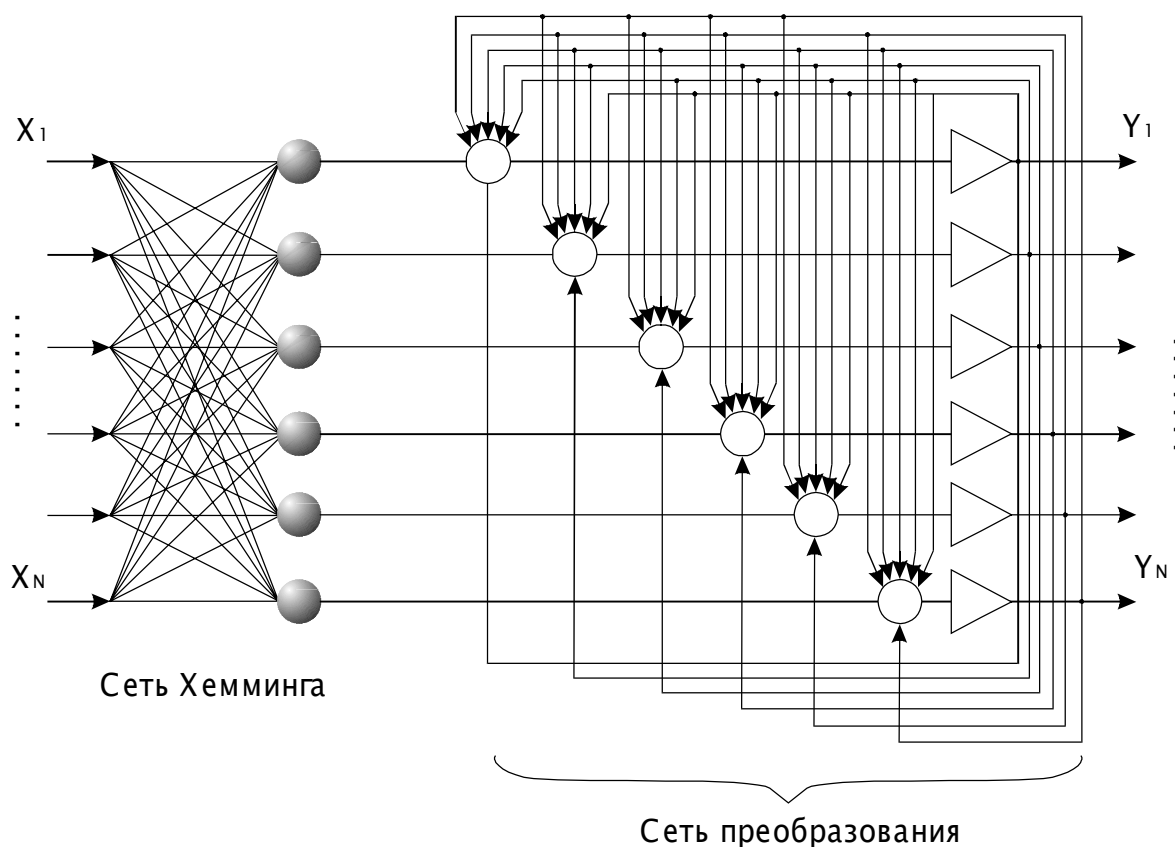


Рис.2.15

На рисунке 2.15 первый слой, называемый подсетью или сетью Хемминга, вычисляет расстояние Хемминга между входным вектором и вектором, занесенным в память путем изменения значений синаптических весов нейронов сети. Подсеть или сеть преобразования выполняет функцию выбора нейрона из первого слоя, выходной сигнал которого имеет наибольшую амплитуду, то есть нейрон, для которого расстояние Хемминга между входным вектором и вектором-образцом является наименьшим. Такого рода нейрон также называется нейроном-победителем.

Настройка синаптических весов и смещений в рассмотренной сети, осуществляемая путем вычисления расстояния Хемминга, определяется посредством формулы (2.23):

$$w_{i,j} = -x_i^j, b_j = -N, 1 \leq i \leq N, 1 \leq j \leq M. \quad (2.23)$$

Однако в литературе наиболее часто встречается метод вычисления смещения и синаптических весов посредством формулы (2.24):

$$w_{i,j} = \frac{x_i^j}{2}, b_j = \frac{N}{2}, 1 \leq i \leq N, 1 \leq j \leq M, \quad (2.24)$$

где b – смещение,

N – размерность входного сигнала,

M – количество нейронов в сети.

Вид передаточной функции сети Хемминга приведен на рис.2.16. Как видно из рисунка она представляет собой линейную функцию с насыщением.




Рис.2.16

Функция, по которой производится непосредственно функционирование сети Хемминга, представлена в формуле (2.25):

$$y_j = \left(\sum_{i=1}^N w_{i,j} x_i - b_j \right), 1 \leq j \leq M, \quad (2.25)$$

где y_j – выход j -го нейрона сети.

Сеть Хемминга может распознавать только слабозашумленные входные сигналы, что также ограничивает возможность ее применения в задаче распознавания изображений. Однако сама возможность использования данной сети для распознавания зашумленных изображений, а также возможность несовпадения размерностей входного и выходного сигналов сети делает ее использование более выгодным, чем, например, использование сети Хопфилда в задачах распознавания. Также стоит упомянуть о высоком быстродействии сети вследствие того, что выходной сигнал формируется в результате прохода всего лишь одного слоя нейронов. Это важно рассматривать в сравнении, например, с сетями циклического функционирования, когда сигнал многократно проходит через нейроны в слоях сети, и количество слоев, таким образом, в большой степени определяет быстродействие сети в целом. Обучение сети реализуется на базе довольно простого алгоритма, основанного на вычислении расстояния Хемминга, что также определяет высокую скорость обучения сети. В отличие от сети Хопфилда, емкость сети Хемминга не зависит от размерности входного сигнала, она в точности равна количеству нейронов (M).

2.3.8. Сеть MAXNET

Большинство НС выделяют нужный сигнал из набора входных векторов по принципу его максимального значения, либо, в случае выделения комбинации нескольких входных сигналов, организуется некоторый порог, превышение которого дает право на подачу текущего входа на выход сети. В сетях MAXNET при этом используется принцип «победитель забирает все», который гласит о том, что только один входной сигнал из набора, имеющий наиболее высокое значение, организует комбинацию выходных сигналов сети. Выбор нужного входного сигнала в MAXNET обычно реализуется путем постепенного уменьшения значений всех входных сигналов, пока не останется положительным значение единственного входа, изначально имевшего максимальную величину. Р. Липпманом был предложен другой способ нахождения максимального значения на входе, который базируется на жестком ограничении числа нейронов, участвующих в операции бинарного сравнения входных сигналов [22]. Значения синаптических весов и порогов выходных нейронов устанавливаются такими же, как и у того выходного нейрона, положительное значение которого может быть получено только в том случае, если результат бинарного сравнения всех сигналов на входном слое нейронов покажет, что соответствующий ему входной сигнал имеет максимальное значение. Ограничение числа нейронов в сети при этом является довольно высокой величиной в случае большого количества входных сигналов (M), так как для осуществления операции их сравнения требуется $O(M^2)$ нейронов. Например, для нахождения максимума среди 100 входных сигналов требуется 5050 нейронов. В другом типе сети MAXNET, описанной Липпманом [22], для определения максимума среди M входов организуется $(M-1)$ подсетей сравнения, расположенных в нижних слоях бинарного дерева, то есть округленно $\log_2 M$ слоев. В этом случае для реализации той же задачи потребовалось бы уже 594 нейрона.

MAXNET – это комплексная нейронная сеть небольшого объема, в которой используются прямо-обратные связи. В случае требования в исходной задаче зависимости количества нейронов в сети от размерности входного сигнала, обычно выбирают именно сети MAXNET. Данная НС может провести операцию классификации входного изображения в случае присутствия в нем помех, занимающих до 30% полезного сигнала, причем количество итераций при этом рассчитывается как 10% от M . Причем зависимость количества итераций от числа элементов сети является линейной.

По своей структуре MAXNET очень похожа на сеть Хопфилда, однако отличается наличием пороговой логики, регулирующей количество нейронов в сети, а также наличием обратной связи от выходных нейронов к входам сети. Схематическое изображение структуры сети показано на рис. 2.17. В нулевой момент времени входные сигналы проходят через первый слой нейронов сети, то есть слой входных нейронов. Они же производят инициализацию выходных нейронов в тот же момент времени ($\mu_j(0)$):

$$\mu_j(0) = y_j, \quad j = 0, 1, \dots, M-2, M-1. \quad (2.26)$$

Согласно формуле (2.27) производятся итерации в сети, в результате которых определяется максимальное значение на входе:

$$\mu_j(t+1) = f \left[\mu_j(t) - \sum_{i \neq j} w_{ij} \mu_i(t) \right], \quad (2.27)$$

где f – логическая пороговая функция (2.28), описанная в [22],
 w_{ij} – синаптические веса между нейронами.




Рис. 2.17

$$f(\alpha) = \begin{cases} \alpha, & \text{если } \alpha \geq 0 \\ 0, & \text{если } \alpha \leq 0 \end{cases}. \quad (2.28)$$

Алгоритм функционирования сети очень прост: в нулевой момент времени на входной слой сети подается сигнал, потом он снимается и, через некоторое время, необходимое на переорганизацию сети, с выходного слоя можно снимать результирующий сигнал. Время переорганизации сети также называется временем сходимости. Все нейроны сети это аналоговые элементы с пороговым уровнем срабатывания, имеющие внутренний порог равный нулю. как показано на схеме, каждый нейрон соединен со всеми остальными нейронами сети, а также имеет обратную связь, с помощью которой он замыкается на себя. После схождения только один выходной нейрон, соответствующий максимальному входному сигналу имеет ненулевое значение на выходе. Таким образом формирование выходного сигнала сети составляется согласно формуле (2.29):

$$z_j = \mu_j(\infty), \quad j = 0, 1, \dots, M-2, M-1. \quad (2.29)$$

Причем сеть MAXNET начинает операцию схождения и нахождения максимального входного сигнала, когда верно условие (2.30):

$$w_{ij} = w < \frac{1}{M-1}. \quad (2.30)$$

Существует вариант модификации сети, когда каждый нейрон присоединен к другим нейронам сети через динамически изменяемые синаптические веса $w_{ij}(t)$. Соединение внутри каждого нейрона между его входом и выходом имеет неизменяемое в процессе обучения значение. Во время каждой итерации каждый активный нейрон i (выход которого $\mu_i > 0$) обновляется согласно формуле (2.31):

$$\mu_i(t+1) = f \left[\mu_i(t) - \sum_{j=1}^M w_{ij}(t) \mu_j(t) \right]. \quad (2.31)$$

После обновления всех нейронов, $M(t+1)$, количество активных нейронов на текущий момент времени рассчитывается, и веса соединений между нейронами переопределяются по формуле (2.32):

$$w_{ij}(t+1) = \frac{1}{M(t+1)}. \quad (2.32)$$

Веса инициализируются согласно правилу $M(0)=M$, где M – это количество всех нейронов в сети.

Данный алгоритм, предложенный Липпманом [22], отличается от стандартного тем, что синаптические веса в сети динамически изменяются. По этому алгоритму количество требуемых итераций для проведения операции схождения или обучения сети существенно уменьшается. Этот параметр бывает очень существенным в случае большого количества нейронов в сети, так как влияет на ее быстродействие. В оригинальной сети количество итераций прямо пропорционально количеству нейронов, и поэтому может иметь слишком большое значение. В данной же модификации количество итераций пропорционально логарифмическому значению количества нейронов в сети.

Таким образом можно привести основную теорему функционирования модифицированной сети MAXNET:

модифицированная сеть MAXNET будет инициализироваться только в том случае, если не более одного нейрона сети будет иметь максимальное значение, и обучаться в течение того времени, пока только один нейрон не останется активен, то есть иметь на выходе ненулевое значение.

Следовательно можно привести, в качестве одного из основных недостатков сети, ее малое быстродействие, то есть длительное время обучения, зависящее от числа нейронов в сети. Однако основным преимуществом для MAXNET является предельная простота ее работы, а следовательно и простота ее программной реализации.

2.3.9. ART-1 сети

Как обучать новым явлениям (приобрести пластичность) и в то же время сохранить стабильность, чтобы существующие знания не были стерты или разрушены? Карпенгер и Гроссберг, разработавшие модели теории адаптивного резонанса (ART1, ART2 и ARTMAP), сделали попытку решить эту дилемму. Сеть имеет достаточное число выходных элементов, но они не используются до тех пор, пока не возникнет в этом необходимость. Обучающий алгоритм корректирует имеющийся прототип категории, только если входной вектор в достаточной степени ему подобен. В этом случае они резонируют. Степень подобия контролируется параметром сходства k , $0 < k < 1$, который связан также с числом категорий. Когда входной вектор недостаточно подобен ни одному существующему прототипу сети, создается новая категория, и с ней связывается нераспределенный элемент с входным вектором в качестве начального значения прототипа. Если не находится нераспределенного элемента, то новый вектор не вызывает реакции сети. В соответствии с этим алгоритмом первый входной сигнал считается образцом первого кластера. Следующий входной сигнал сравнивается с образцом первого кластера. Говорят, что входной сигнал "следует за лидером" и принадлежит первому кластеру, если расстояние до образца первого кластера меньше порога. В противном случае второй входной сигнал - образец второго кластера. Этот процесс повторяется для всех следующих входных сигналов. Таким образом, число кластеров растет с течением времени и зависит как от значения порога, так и от метрики расстояния, используемой для сравнения входных сигналов и образцов классов. Основная часть сети ART-1 (рис. 2.18) схожа с сетью Хемминга, которая дополнена полносвязной сетью MAXNET. С помощью последовательных связей рассчитывается соответствие входных сигналов и образцов кластеров. Максимальное значение соответствия усиливается с помощью взаимного латерального торможения выходных нейронов. Сеть ART-1 отличается от сети Хемминга обратными связями от выходных нейронов к входным, кроме того, имеется возможность выключать выходной нейрон с




Рис. 2.18

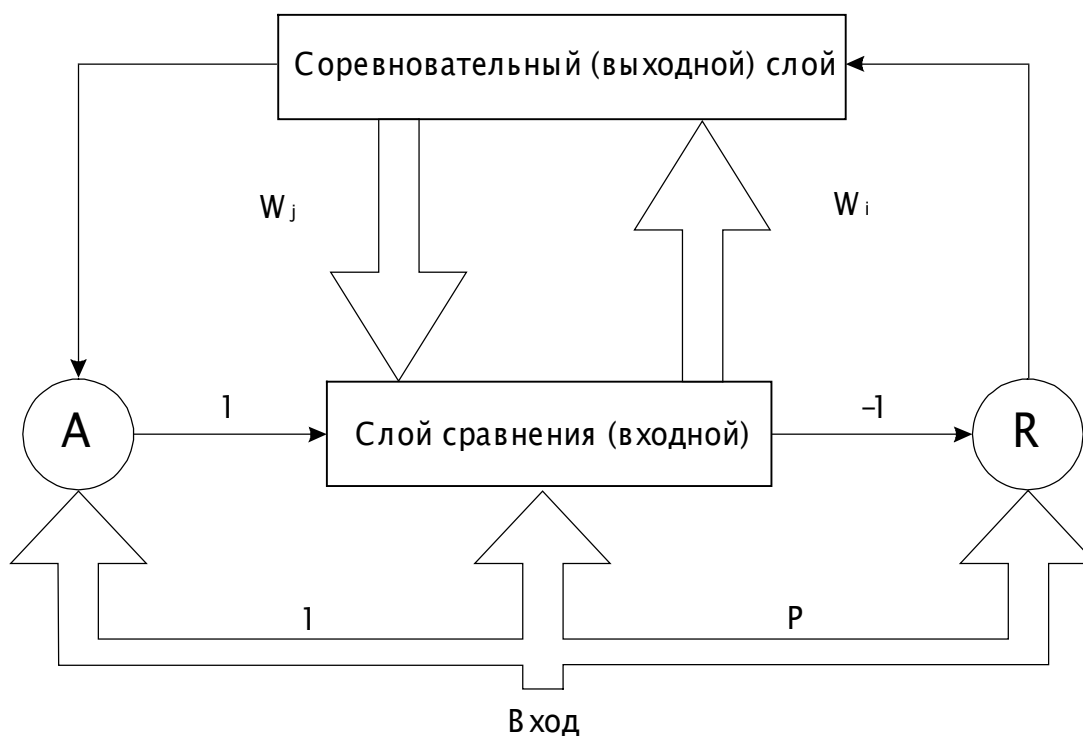


Рис. 2.19

максимальным значением соответствия и проводить пороговое тестирование соответствия входного сигнала и образцов кластеров, как того требует алгоритм "последовательного лидера" (sequential leader clustering algorithm).

Чтобы проиллюстрировать модель, рассмотрим сеть ART1, которая рассчитана на бинарный (0/1) вход. Упрощенная схема архитектуры ART1 [21] представлена на рис. 2.19. Она содержит два слоя элементов с полными связями. Направленный сверху вниз весовой вектор W_j соответствует элементу j входного слоя, а направленный снизу вверх весовой вектор i связан с выходным элементом i ; i является нормализованной версией W_i . Векторы W_j сохраняют прототипы кластеров. Роль нормализации состоит в том, чтобы предотвратить доминирование векторов с большой длиной над векторами с малой длиной. Сигнал сброса R генерируется только тогда, когда подобие ниже заданного уровня.

Модель ART1 может создать новые категории и отбросить входные примеры, когда сеть исчерпала свою емкость. Однако число обнаруженных сетью категорий чувствительно к параметру сходства.

Приведем алгоритм функционирования сети.

1. Инициализация сети.

$$\begin{aligned}
 t_{ij}(0) &= 1, \\
 b_{ij}(0) &= \frac{1}{1+N}, \\
 0 \leq i \leq N-1, 0 \leq j \leq M-1, 0 \leq r \leq 1
 \end{aligned} \tag{2.33}$$

где $b_{ij}(t)$ - синаптический вес связи от i -го нейрона первого слоя к j -му нейрону второго слоя в момент времени t (bottom up),

$t_{ij}(t)$ - синаптический вес связи от i -го нейрона второго слоя к j -му нейрону первого слоя в момент времени t (top down),

r - значение порога.

Веса $t_{ij}(t)$ и $b_{ij}(t)$ определяют образец, соответствующий нейрону j . Порог r показывает, насколько должен входной сигнал совпадать с одним из запомненных образцов, чтобы они считались похожими. Близкое к единице значение порога требует почти полного совпадения. При малых значениях порога даже сильно отличающиеся друг от друга входной сигнал и образец считаются принадлежащими одному кластеру.

2. Предъявление сети нового бинарного входного сигнала.

Входные сигналы предъявляются нижнему слою нейронов аналогично тому, как это делается в сети Хемминга.

3. Вычисление значений соответствия.

$$y_j = \sum_{i=0}^{N-1} b_{ij}(t)x_j, \quad 0 \leq j \leq M-1. \tag{2.34}$$

Значения соответствия вычисляются параллельно для всех образцов, запомненных в сети, аналогично сети Хемминга

4. Выбор образца с наибольшим соответствием.

$$y_j = \max(y_j). \tag{2.35}$$

Данная операция выполняется с помощью латерального торможения аналогично сети MAXNET.

5. Сравнение с порогом.

$$\begin{aligned}
 \|X\| &= \sum_{j=0}^{N-1} x_j, \\
 \|T \cdot X\| &= \sum_{j=0}^{N-1} t_{ij} x_j,
 \end{aligned}
 \left\{ \begin{array}{l}
 \frac{\|T \cdot X\|}{\|X\|} > r, \text{ goto step 7} \\
 \frac{\|T \cdot X\|}{\|X\|} > r, \text{ goto step 6}
 \end{array} \right. \tag{2.36}$$

На этом шаге вычисляется отношение скалярного произведения входного сигнала и образца с наибольшим значением соответствия к числу единичных бит входного сигнала. Значение отношения сравнивается с порогом, введенном на первом шаге. Если значение отношения больше порога, то входной сигнал считается похожим на образец с наибольшим значением соответствия. В этом случае образец модифицируется путем выполнения операции AND (логическое "И"). Новый образец есть образец на предыдущем шаге AND входной сигнал. Если значение отношения меньше порога, то считается, что входной сигнал отличается от всех

образцов, и он рассматривается как новый образец. В сеть вводится нейрон, соответствующий новому образцу, и рассчитываются значения синаптических весов.

6. *Исключение примера с наибольшим значением соответствия.*

Выход нейрона с наибольшим значением соответствия временно устанавливается равным нулю и более не принимает участие в 4-м шаге.

7. *Адаптация примера с наибольшим значением соответствия.*

$$t_{ij}(t+1) = t_{ij}(t)x_j,$$

$$b_{ij}(t+1) = \frac{t_{ij}(t)x_j}{0.5 + \sum_{j=0}^{N-1} t_{ij}(t)x_j}. \quad (2.37)$$

8. *Включение всех исключенных на 6-м шаге образцов. Возвращение к шагу 2.*

Одним из наибольших недостатков метода является неограниченное увеличение числа нейронов в процессе функционирования, которое может также приобрести неуправляемый характер в случае присутствия шумов на входном сигнале. В настоящее время используется модификация модели ART, которая называется ART-2, основным преимуществом которой, по сравнению с предыдущими модификациями, является возможность работы с непрерывными значениями входных сигналов.

2.3.10. Самоорганизующиеся карты Кохонена

Задача категоризации объектов по их общим признакам является трудной, но необходимой задачей. Самоорганизующиеся карты, созданные Кохоненом в промежутке между 1979 и 1982 годами, представляют собой наиболее приемлемую структуру нейронной сети, находящуюся между сетями Хопфилда и сетью Адалина.

Функционирование самоорганизующихся карт Кохонена подчинено одной главной цели: создание двухмерной карты характеристик входного изображения, причем сохранение в этой карте не только самих характеристик, но также и последовательность их поступления на входы сети. Другими словами, алгоритм Кохонена дает возможность строить нейронную сеть для разделения векторов входных сигналов на подгруппы. Входные сигналы - вектора действительных чисел - последовательно предъявляются сети. Желаемые выходные сигналы не определяются. После того, как было предъявлено достаточное число входных векторов, синаптические веса сети определяют кластеры. Кроме того, веса организуются так, что топологически близкие узлы чувствительны к похожим внешним воздействиям (входным сигналам). Одной из основных характеристик карт Кохонена является то, что они могут обучаться без учителя, самоорганизуя структуру поступающих сигналов, легко взаимодействуя при этом с другими типами сетей в задачах категоризации и классификации. Они позволяют нам построить набор особенностей входных векторов, в котором сконцентрирована интересующая нас в рамках данной проблемы информация, используя в этом случае нелинейный метод, через который карта и создается. Нелинейность метода объясняется присутствием в комплексе с входным слоем адаптивного слоя, который со временем (в течение обучения) меняет свою структуру, преобразуясь в пространственно заданную карту особенностей входных векторов. Другими словами, положение элементарной единицы в слое Кохонена является показателем очередной особенности входного сигнала со статистической точки зрения, то есть определенной через анализ плотности распределения различных характеристик.

Количество активизированных единиц в слое Кохонена напрямую связано с количеством сгруппированных кластеров характеристик входных векторов.

Таким образом, самоорганизация, при обучении без учителя, представляет собой сжатие данных в двухмерную карту без потери информации входного сигнала, что в принципе делает эту модель сети более способной к выживанию с биологической точки зрения, по сравнению с другими моделями. Так как в человеческом мозге нейроны располагаются так, что некоторые внешние физические воздействия вызывают ответную реакцию нейронов из определенной области мозга. Например, в той части мозга, которая отвечает за восприятие звуковых сигналов, нейроны группируются в соответствии с частотами входного сигнала, на которых они резонируют. Хотя строение мозга в значительной степени предопределяется генетически, отдельные структуры мозга формируются в процессе самоорганизации. Алгоритм Кохонена в некоторой степени напоминает процессы, происходящие в мозге. С точки зрения вычислительных процессов карты Кохонена могут рассматриваться как нелинейное обобщение результатов анализа основных составляющих входного сигнала. В этом контексте они демонстрируют себя как наиболее приемлемая модель нейронной сети применительно к задачам от распознавания изображений до адаптивного управления роботами.

Сеть состоит из M нейронов, образующих прямоугольную решетку на плоскости (рис. 2.20). Элементы входных сигналов подаются на входы всех нейронов сети. В процессе работы алгоритма настраиваются синаптические веса нейронов. Для реализации алгоритма необходимо определить меру соседства нейронов (меру близости). На рис.




Рис.2.20

2.21 показаны зоны топологического соседства нейронов на карте признаков в различные моменты времени. $NE_j(t)$ - множество нейронов, которые считаются соседями нейрона j в момент времени t . Зоны соседства уменьшаются с течением времени.




Рис.2.21

Приведем алгоритм Кохонена формирования карт признаков входных векторов:

1. *Инициализация сети.*

Весовым коэффициентам сети присваиваются малые случайные значения. Общее число синаптических весов равно $(M \cdot N)$. Начальная зона соседства на карте признаков для момента времени $t=0$ показана на рис.2.21.

2. *Подача на сеть нового входного сигнала.*

3. *Вычисление расстояния Кохонена между входными векторами и нейронами.*

Расстояние d_j от входного сигнала до j -го нейрона определяется по формуле (2.38):

$$d_j = \sum_{i=0}^{N-1} (x_i(t) - w_{i,j}(t))^2, \quad (2.38)$$

где x_i – i -й элемент входного сигнала в момент времени t ,

$w_{i,j}(t)$ – вес связи от i -го элемента к нейрону j в момент времени t .

4. *Выбор нейрона с наименьшим расстоянием.*

Выбирается нейрон j^* , для которого расстояние d_j наименьшее.

5. *Настройка весов нейрона j^* и его соседей.*

Производится подстройка весов для нейрона j^* и всех нейронов из его зоны соседства NE. Новые значения весов получаются по формуле (2.39):

$$w_{i,j}(t+1) = w_{i,j}(t) + r(t)(x_i(t) - w_{i,j}(t)), \quad (2.39)$$

где $r(t)$ – шаг обучения, положительное число меньше единицы, которое уменьшается с течением времени.

6. *Возвращение к шагу 2.*

Основным отличием от сети ART Гроссберга и достоинством самоорганизующихся карт Кохонена является их способность функционировать в условиях помех на входном сигнале, так как число классов является фиксированным, настройка весов производится медленно и заканчивается не в процессе обучения, как в сети ART, а после его окончания. Однако неприятной стороной в данном вопросе является то, что число кластеров должно быть заранее известным.

Самоорганизующиеся карты Кохонена могут быть использованы для проектирования многомерных данных, аппроксимации плотности и кластеризации. Эта сеть успешно применялась для распознавания речи, обработки изображений, в робототехнике и в задачах управления [21]. Одним из наиболее известных способов определения нейрона с наименьшим расстоянием Кохонена является применение сети MAXNET, которая используется совместно с самоорганизующимися картами.

2.3.11. Генетические алгоритмы обучения НС

Начало теории генетических алгоритмов (ГА) положил Дж. Холланд в первом издании своей знаменитой книги в 1975 году [20]. Правда генетическими они стали называться позднее, а в 1975 году Холланд называл их репродуктивными планами (*reproductive plan*) и рассматривал прежде всего как алгоритмы адаптации. Почти два десятилетия исследований ушли на доказательство грани могущества теории ГА в области *глобальной оптимизации*. Но не стоит забывать и о неплохих результатах применения ГА в теории адаптации и обучения.

ГА базируются на теоретических достижениях синтетической теории эволюции, учитывающей микробиологические механизмы наследования признаков в природных и искусственных популяциях организмов. Методологическая теория ГА основана на гипотезе селекции, которая может быть сформулирована в общем виде так: чем выше приспособленность особи, тем выше вероятность того, что в потомстве, полученном с ее участием, признаки, определяющие приспособленность, будут выражены еще сильнее. Чаще всего особи, обладающие низкой приспособленностью, не только не участвуют в генерации нового поколения, а элиминируются из популяции на текущем дискретном шаге (эпохе) эволюции. Итак, здесь незримо присутствует основная гипотеза селекции – в качестве родительских всегда выступают *лучшие* в фенотипическом отношении, а не произвольные точки (особи) из популяции потенциальных решений, неудачные же решения отбрасывают на текущем шаге. Таким образом можно выделить те характеристики, которые ГА заимствуют из биологии:

- идею о преимущественном размножении наиболее приспособленных особей;
- способы передачи генетической информации в чередующихся поколениях (генетические операторы);
- понятийный аппарат;
- идею коллективного поиска экстремума при помощи популяции особей;
- способы представления генетической информации.

Рассмотрим два парадигма теории ГА : представление генетической информации и генетические операторы, более подробно.

Первая проблема построения алгоритмов генетической эволюции - это кодировка информации, содержащейся в модели НС. Коды называют "хромосомами". Для фиксированной топологии (архитектуры) НС эта информация полностью содержится в значениях синаптических весов (W) и смещений (B). Вектор (W, B) рассматривается как хромосома. Возможны более сложные способы кодирования информации. Для простоты изложения приведем пример бинарного кодирования, используемый при моделировании эволюции гаплоидных популяций. Будем считать, что каждая переменная x_i кодируется определенным фрагментом хромосомы, состоящим из фиксированного количества генов (см. рис. 2.22). Все локусы хромосом диаллельны- то есть в любой позиции фрагмента может стоять как ноль, так и единица. Рядом стоящие фрагменты не отделяют друг от друга какими-либо маркерами, тем не менее, при декодировании хромосомы в вектор переменных на протяжении всего моделируемого периода эволюции используется одна и та же маска картирования.




Рис. 2.22

Хотя мы постоянно говорим о декодировании, на самом деле прямая операция, понимаемая как операция кодирования вектора переменных X в хромосому A , в ГА не применяется. Хромосомы генерируются случайным образом, путем последовательного заполнения разрядов (генов), сразу в бинарном виде, и всякие последующие изменения в популяции затрагивают сначала генетический уровень, а только потом анализируются фенотипические последствия этих изменений, но не наоборот. В принципе, для декодирования генетической информации из бинарной формы к десятичному виду подходит любой двоично-десятичный код, но обычно исходят из того, что она представлена в коде Грея. От кода Грея переходим к двоично-десятичному коду, а от него – к натуральным целым числам.

Одним из главных итогов изучения ГА на настоящий момент стало понимание прекрасной взаимной комплиментации триады генетических операторов (ГО) «кроссовер – мутация – инверсия». Воздействуя с некоторой вероятностью на генотипы родительских особей, каждый из них, с одной стороны, обеспечивает передачу потомству жизненно важных признаков, а с другой – поддерживает на протяжении эволюционно значимого периода достаточно высокий уровень изменчивости. Выщепление в потомстве новых, отличных от родительских, фенотипических признаков открывает для популяции дополнительные возможности для адаптации, то есть способствует сохранению ее поисковой способности.

В приведенном на рис. 2.23 примере оператор мутации, подобно точечным мутациям в природе, интерпретируется как замена существующего аллельного состояния отдельного гена в хромосоме на противоположное (единицы - на ноль и наоборот). Очевидно, что в зависимости от того, в каком разряде фрагмента, кодирующего переменную, произойдет мутация, зависит величина расстояния, отделяющего потомка от родителя (речь идет о пространстве вещественных чисел). Инверсия приводит к нарушению порядка следования фрагментов хромосом у потомка по сравнению с родительской хромосомой. Наконец, кроссовер, описывающий механизм гаметогенеза в диплоидных популяциях организмов и привнесенный Холландом в моделирование эволюций гаплоидных популяций [20], приводит к тому, что хромосома потомка

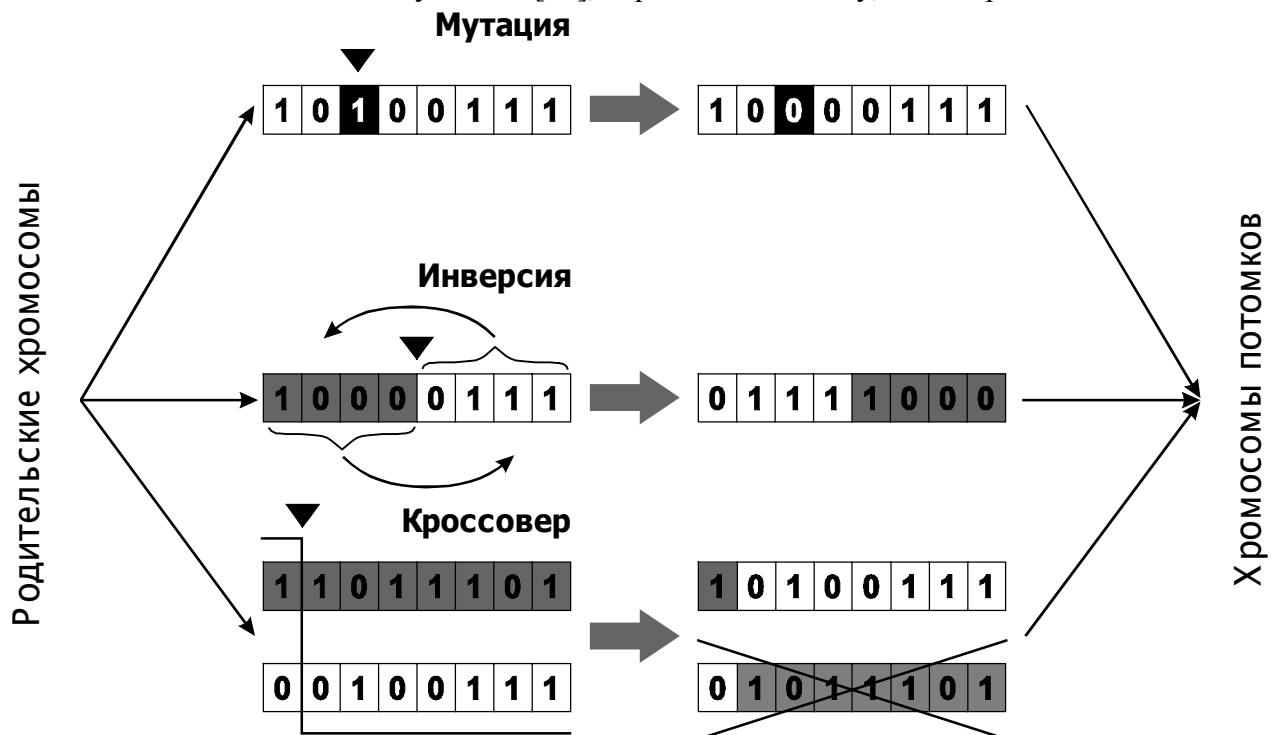


Рис. 2.23

включает два потомка, один из которых принадлежал ранее, условно говоря, отцовской хромосоме, а другой – материнской. Именно благодаря наличию кроссоверных обменов особи популяции обмениваются между собой генетической информацией, то есть поиск приобретает действительно коллективный характер.

На рис. 2.23 у всех трех операторов место приложения, помеченное значком ∇ , выбирается случайно.

Иногда, говоря о триаде ГО, подчеркивают способность кроссовера и инверсии к глобальному поиску, в то время как мутацию отождествляют со средствами локальной настройки решения, отводя ей фоновую роль. Такой распределение ролей представляется спорным, так как мутация может породить потомка далеко за пределами локального экстремума, в котором находится родитель, с другой стороны, кроссовер, проведенный над гометами родителей, расположенных в общем экстремуме, наверняка породит потомков в этом же экстремуме. Важно другое – ни кроссовер, ни мутация не опираются в процессе генерирования потомка на знание локального рельефа поверхности целевой функции. В этом смысле их можно считать глобальными.

В концепции рассмотрения ГА через призму теории НС можно выделить основной способ их применения в качестве метода настройки синаптических весовых коэффициентов узлов сети. Другими словами с помощью ГА можно проводить обучение НС. Преимуществом данного вида обучения является, например, то, что алгоритмы очень эффективны в поиске глобальных минимумов адаптивных рельефов, так как в них исследуются большие области допустимых значений параметров НС. (Градиентные алгоритмы дают возможность находить только локальные минимумы.) Другая причина того, что ГА не застревают в локальных минимумах - случайные мутации, которые аналогичны температурным флуктуациям метода имитации отжига. В качестве другого преимущества можно выделить, что ГА дают возможность оперировать дискретными значениями параметров нейронных сетей. Это упрощает разработку цифровых аппаратных реализаций сетей. При обучении на компьютере НС, не ориентированных на аппаратную реализацию, возможность использования дискретных значений параметров в некоторых случаях может приводить к сокращению общего времени обучения.

В приведенном на рис. 2.24 примере ГА применяется для настройки параметров нейроконтроллера в случае, когда алгоритм обратного распространения ошибки не подходит вследствие того, что он требует информацию об ошибке на эффекторном слое

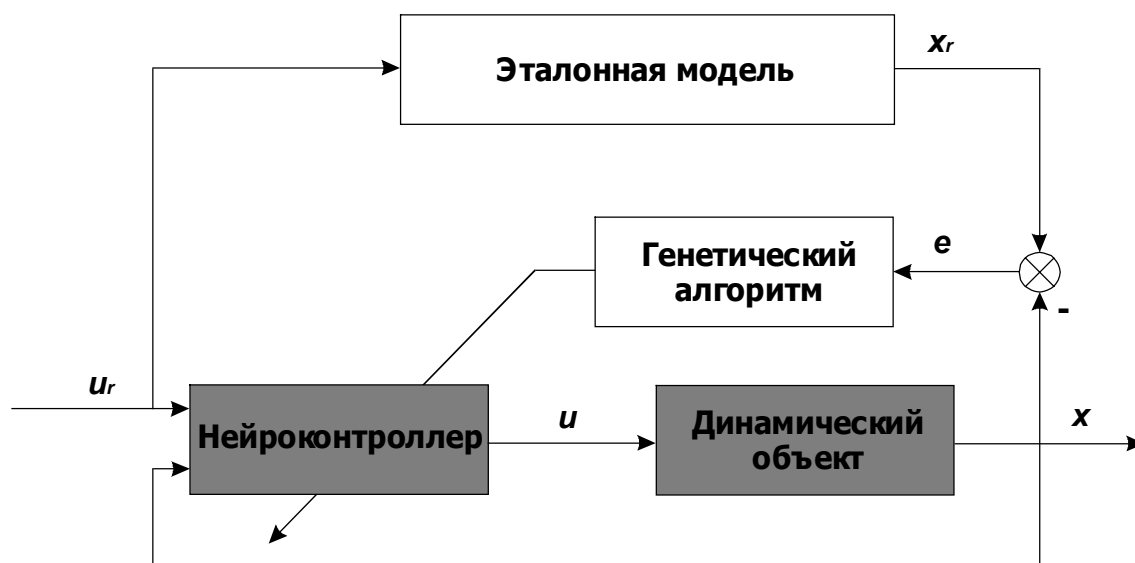


Рис. 2.24

НС. Для получения которой в схеме обучения потребовалось бы предусмотреть обращенный нейроэмулятор объекта, роль которого сводилась бы к преобразованию ошибки на выходе объекта в выходной сигнал на выходе нейроконтроллера, что существенно усложнило бы процедуру обучения.

Генетический же алгоритм настраивает параметры нейроконтроллера не по ошибке в управлении u , а по ошибке в выходе объекта, сравнивая его с выходом эталонной модели. Последняя воплощает в себе наши представления о желаемом поведении объекта, то есть играет приблизительно ту же роль, что и библиотека тренировочных шаблонов в процедуре обучения.

Еще одним преимуществом применения ГА является достаточно высокая скорость обучения, хотя скорость сходимости градиентных алгоритмов в среднем выше, чем генетических. А среди очевидных недостатков можно выделить сложность ГА для понимания и программной реализации. В рамках "генетического" подхода в последнее время разработаны многочисленные алгоритмы обучения НС, различающиеся способами представления данных нейронной сети в "хромосомах", стратегиями репродукции, мутаций, отбора.

2.4. Заключение

В период 1983-86 гг. работы в области ИНС принимают характер настоящего бума. В США, Японии и странах ЕЭС разворачиваются крупные государственные программы исследований, ставящие целью создание к 1995 г. опытных образцов и освоение до 2000 г. массового производства нейрокомпьютеров - ЭВМ нового поколения на основе ИНС. Вот наиболее известные из этих программ [13]:

США - программа DARPA - Управления перспективного планирования НИР военного применения - 1987-1995 гг. - 400 млн. долл.;

Япония - программа Human Frontier - 1988-1996 гг. - 1 триллион иен (6,6 млрд. долл.);

ЕЭС - программа BRAIN (Basic Research on Adaptive Intelligence - Базовые исследования адаптивного интеллекта) - 1988-1996 гг. - 1,2 млн. долл. ежегодно.

Уже в 1987 г. в США состоялись две международные конференции по нейронным сетям, на одной из которых было представлено около 400, а на второй - более 150 докладов. Проведение таких международных форумов по ИНС становится регулярным, а их число вскоре достигает нескольких десятков в год. На наиболее представительной из последних конференций, ICNN-96 (США), было представлено более 500 докладов. В Европе только за сентябрь 1997 г. на конференциях EUFIT-97 (Германия) и ICAP (Италия) прочитано около сотни докладов по ИНС. Государственная поддержка и обильное финансирование разработок привело к быстрому формированию целой исследовательской индустрии, созданию и организации массового производства необходимого аппаратного и программного оснащения: нейрокомпьютеров и нейроакселераторов для ЭВМ, нейрочипов и нейропрограмм, учебных курсов на CD-ROM и т.п. Уже к 1992 г. только в США более 150 компаний специализировались на выпуске различной нейропродукции, раскупаемой университетами и лабораториями, занятыми выполнением исследовательских программ. По оценкам компании Business Communications Company Inc., в конце 1992 г. объем мирового рынка нейрокомпьютеров составлял \$120 млн. (аппаратное обеспечение) и \$50 млн. (программное обеспечение). Предсказывалось, что к 2000-му году он вырастет до \$790 и \$260 млн. соответственно.

В опубликованных недавно обзорных работах даны многочисленные примеры практического применения нейрокомпьютеров и нейротехнологий в системах оборонного и гражданского назначения. Из них складывается картина массированного наступления нейротехнологий во всех сферах человеческой деятельности. Следует, однако, учесть, что все эти примеры относятся к началу 90-х годов - пику нейрокомпьютерного бума, когда в данную отрасль были вовлечены многие тысячи квалифицированных специалистов и в ней образовался мощный научно-технический потенциал. Именно тогда были отработаны ключевые идеи, налажено производство средств моделирования ИНС, а также созданы образцы нейрочипов и нейрокомпьютеров, которые в свою очередь позволяют создавать крупные системы, содержащие десятки тысяч нейронов и выполняющие миллиарды вычислений в секунду. Анализируя последующие работы, в частности содержание докладов на последних международных конференциях (ICNN-96, EUFIT-97), можно увидеть, что большая часть созданного потенциала так и осталась не востребованной. Современные исследователи отдают предпочтение относительно простым прикладным задачам, решение которых можно достичь с помощью сети из нескольких десятков нейронов. Такое предпочтение отчасти можно объяснить ростом доступности инструментальных средств на основе нейропарадигмы обратного распространения или ее аналогов, не позволяющих эффективно моделировать крупные системы.