

## Нейросетевые технологии

Одной из самых сложных областей современной науки является исследование человеческого мозга как многоклеточной системы. Возникновение ментальных состояний (например, распознавание изображений, ощущения, мысли) объясняется эволюцией макроскопических параметров вследствие нелинейных микроскопических взаимодействий нейронов. Если мозг рассматривать как сложную систему нейронов, то его динамику, по предположению, можно описать с помощью нелинейной математики нейронных сетей. Например, распознавание изображений может быть представлено фазовым переходом аналогично тому, как это делается в физике, химии, биологии. Создаются междисциплинарные программы исследований, имеющие целью объяснить синергетику нейронной сети как естественное следствие физической, химической и нейробиологической эволюции, в основе которой лежат некие общие принципы.

**Синергетика** — наука, изучающая нелинейные, динамичные процессы.

С одной стороны, *синергетика* — эта наука, возникшая как продолжение методов кибернетики, теории систем, теории информации и других наряду с понятиями «самоорганизация», «нелинейность», «открытость», «хаос» сложилась как инструмент исследования сложных процессов. Теория нелинейных сложных систем стала успешным подходом к решению проблем в естественных науках — от физики лазеров и твёрдого тела, химии и метеорологии до моделей биологического, нейронного и экологического развития. С другой стороны, экономисты, социологи, политики приходят к выводу, что основные проблемы человечества также отличаются глобальностью, сложностью и нелинейностью. Однако применение методов и технологий синергетики к социоэкономическим процессам должно осуществляться с учётом сущностных различий физического и социального миров. Совокупность общественных отношений, экономические факторы, человеческие чувства, мысли, свобода воли — всё это порождает эволюционные процессы, ведущие к созданию более сложных организаций и структур путём интеграции различных, развивающихся в разном темпе структур в целостные системы.

Возрождение интереса к нейронным сетям объясняется успешными техническими приложениями статистической механики и нелинейной динамики к физике твёрдого тела, к лазерным системам. Другой причиной выступают развитие вычислительных ресурсов и повышение уровня технологии, делающие всё более доступным компьютерное моделирование систем.

На рынке коммерческих программных продуктов наряду с аналитическими инструментами нового поколения, основанными на применении логики нечётких множеств — от электронных таблиц (*Fuzzy Calc*) до экспертных систем (*Cabi Calc*) корпорации Nureg Jodic (США), всё больший интерес для финансово-экономической деятельности представляют аналитические информационные технологии, основанные на использовании **искусственных нейронных сетей**.

Под искусственными нейронными сетями (далее — просто нейронными сетями) подразумевают вычислительные структуры, состоящие из большого количества однотипных элементов, каждый из которых выполняет относительно простые функции. Процессы в искусственных нейросетях иногда ассоциируют с процессами, происходящими в нервной системе живых организмов. Бурно развивающийся в последние годы аппарат нейронных сетей предназначался в начале в основном для решения задач классификации, кластеризации и распознавания образов, но дальнейшее развитие данного направления значительно расширило сферу применения нейросетевого подхода, и он начал применяться, в частности, в задачах управления.

**Нейронные сети** — обобщённое название групп алгоритмов, которые умеют обучаться на примерах, извлекая скрытые закономерности из потока данных.

Нейросетевые технологии в отличие от экспертных систем предназначены для воспроизведения неосознанных мыслительных процессов человека (например, человек плохо знает, как он распознаёт цвет предмета). Такого рода технологии работают по аналогии с принципами строения и функционирования нейронов головного мозга человека и используются для распознавания каких-либо событий или предметов. С их помощью можно воспроизвести многочисленные связи между множеством объектов. *Принципиальное отличие искусственных нейросетей от обычных программных систем, например экспертных, состоит в том, что они не требуют программирования. Они сами настраиваются, т.е. обучаются тому, что требуется пользователю.*

Задачи, решаемые информационными системами, в большинстве случаев можно свести к ряду типовых, среди которых нейросетевые технологии и позволяют решать следующие:

- 1) Распознавание человеческой речи и абстрактных образов.
- 2) Классификацию образов — определение принадлежности образа к одному или нескольким предварительно определённым классам.
- 3) Кластеризацию — разделение образов на заранее не определённые классы по каким-либо признакам.
- 4) Классификацию состояний сложных систем.
- 5) Аппроксимацию функций — оценку неизвестной зависимости по экспериментальным данным.
- 6) Прогноз (предсказание) — определение будущего процесса по его прошлому и настоящему.
- 7) Оптимизацию — нахождение решений, которые максимизируют или минимизируют определённый критерий качества при заданных ограничениях.
- 8) Память, адресуемую по содержанию (ассоциативную память), — память, доступную по указанному содержанию.
- 9) Управление — перевод и поддержание системы в требуемом состоянии.

Из приведённых выше задач — задача управления является самой сложной, в большинстве случаев для её решения как вспомогательные требуется решить также другие приведённые здесь задачи.

Известны следующие сферы применения нейросетей:

- 1) экономика и бизнес:
  - управление технологическими процессами и финансовыми потоками;
  - предсказание поведения рынков;
  - предсказание банкротств;
  - оценка стоимости недвижимости;
  - автоматическое рейтингование;
  - оценка кредитоспособности;
  - прогнозирование курса валют;
  - решение аналитических, исследовательских, прогнозных задач, связанных с обширными информационными потоками.
- 2) медицина — обработка медицинских изображений, диагностика, выбор сочетания различных лекарственных препаратов и др.;
- 3) Internet — ассоциативный поиск информации;
- 4) автоматизация производства — оптимизация режимов производственного процесса, диагностика качества продукции, предупреждение аварийной ситуации;

- 5) политические технологии — обобщение социологических опросов;
- 6) безопасность и охранные системы — системы идентификации личности, распознавание автомобильных номеров и аэрокосмических снимков;
- 7) геологоразведка — анализ сейсмических данных, оценка ресурсов месторождений.

Являясь мощным технологическим инструментом, нейросетевые технологии облегчают специалисту процесс принятия важных и неочевидных решений в условиях неопределённости, дефицита времени и ограниченных информационных ресурсов. Нейросети будут предпочтительны также там, где имеется очень много входных данных, в которых скрыты закономерности. В этом случае можно почти автоматически учесть различные нелинейные взаимодействия между показателями-признаками, характеризующими такие данные. Это особенно важно в системах обработки информации (распределённых базах данных, телекоммуникационных и экспертных системах), в частности, для её предварительного анализа или отбора, выявления «выпадающих фактов» или грубых ошибок человека, принимающего решения. *Целесообразно использовать нейросетевые методы в задачах с неполной или «зашумленной» информацией, а также в таких, где решение можно найти интуитивно.*

С середины 1980-х годов нейронные сети начали использоваться на Западе преимущественно в финансовых и военных приложениях. Однако, несмотря на успех, инструмент оказался слишком сложным и дорогостоящим.

Ситуация изменилась в начале 1990-х годов, когда на рынке появилось новое поколение нейросетевых технологий — мощных, недорогих, простых в использовании: Forecast Expert фирмы «Про-Инвест-Консалтинг» для анализа временных рядов и Stat-Media фирмы «Полихимэкс» для классификации данных, которые существенно упрощают процесс построения моделей. Одним из лидеров рынка стал нейросетевой пакет **Brain Maker Pro** американской фирмы California Scientific Software. Он, как и все прочие нейропакеты, реализует универсальные алгоритмы вычислительной математики, независимые от предметной области их применения. Разработанный по заказу военных пакет был адаптирован для бизнес-приложений и с 1990 года удерживает лидерство среди самых продаваемых нейросетевых пакетов США.

Свой путь на российский рынок нейронные сети начали с финансово-кредитной сферы, где заинтересованные в совершенствовании аналитической работы банки стали интенсивно включать нейронные сетевые технологии в состав финансовых приложений. В настоящее время пользователями Brain Maker Pro стали уже более 200 банков и торговых компаний, а последнее время — и аналитические учреждения верхних эшелонов власти.

Преимущества нейросетей становятся заметными тогда, когда довольно часто изменяются «правила игры». Именно поэтому нейросети подходят для определения состояния фондового рынка, характеризующегося целым набором постоянно изменяющихся показателей-признаков.

Отличительной чертой нейронных сетей является их способность менять свое поведение (обучаться) в зависимости от изменения внешней среды, извлекая скрытые закономерности из потока данных. При этом алгоритмы обучения не требуют каких-либо предварительных знаний о существующих в предметной области взаимосвязях — необходимо только подобрать достаточное число примеров, описывающих поведение моделируемой системы в прошлом.

Основанная на нейросетях технология не предъявляет повышенных требований к точности входных данных, как на этапе обучения, так и при её использовании (после настройки и обучения), например при распознавании симптомов приближения критических ситуаций, для краткосрочных, а иногда и долгосрочных прогнозов. Таким образом, нейросетевая технология обладает двумя чрезвычайно полезными свойствами:

- 1) Способностью обучаться на конкретном множестве примеров.

2) Умение стабильно распознавать, прогнозировать новые ситуации с высокой степенью точности, причём в условиях внешних помех, например появления противоречивых или неполных значений в потоках информации.

Взяв за основу работу мозга, нейросетевые технологии включили в себя и ряд биологических терминов, понятий, параметров, а метод получил название генетического алгоритма.

## Нейросеть с точки зрения моделирования сложных систем

К настоящему времени разработано большое количество различных типов нейросетей, имеющих свои отличительные особенности.

В задачах управления наиболее широкое распространение получили многослойные нейросети прямого распространения, или многослойные *перцептроны*, сокращенно — MLP (от англ. Multi Layer Perceptron).

Нейросеть всегда строится на основе заданного множества примеров (например — на данных о состояниях рынков). Сеть состоит из искусственных нейронов, элементарных преобразователей, соединенных друг с другом информационными связями, определяемыми «рёбрами» этой структуры.

Одним из главных отличий нейросетей, повышающим эффективность вычислительного процесса, является возможность распараллеливания вычислений. В её основе лежит понятие «искусственного нейрона», который позволяет реализовать на практике нелинейную функцию многих переменных. Она отображает совокупность входных переменных в вещественное число из отрезка (0, 1) и зависит от набора  $W$  числовых коэффициентов (синаптических весов), рассматриваемого в качестве параметра этой функции. Последняя имеет вполне определённый вид и реализуется двумя элементами — сумматором и нелинейным преобразователем. Первый вычисляет взвешенную сумму входных значений, т.е. компонент вектора признаков, второй выполняет само нелинейное преобразование

$$F(X; W),$$

где  $W$  — набор весов на входе нейрона,

$X$  — входной сигнал.

Искусственный нейрон, или просто нейрон, назван так по аналогии с биологическим прототипом. Один нейрон работает следующим образом: на его вход поступает набор входных сигналов, нейрон суммирует входные сигналы и генерирует выходной, который направляется либо в другие нейроны, либо на выход сети. Искусственный нейрон обычно представляют в виде структуры, приведённой на рисунке 1.

Такой нейрон имеет  $n$  входов  $x_1, x_2, \dots, x_n$  и один выход  $z$ , а его математическая модель описывается соотношениями

$$s = \sum_{j=1}^n w_j \cdot x_j + b, \tag{1.1}$$

$$z = F(s),$$

где  $w_1, w_2, \dots, w_n$  — весовые коэффициенты;

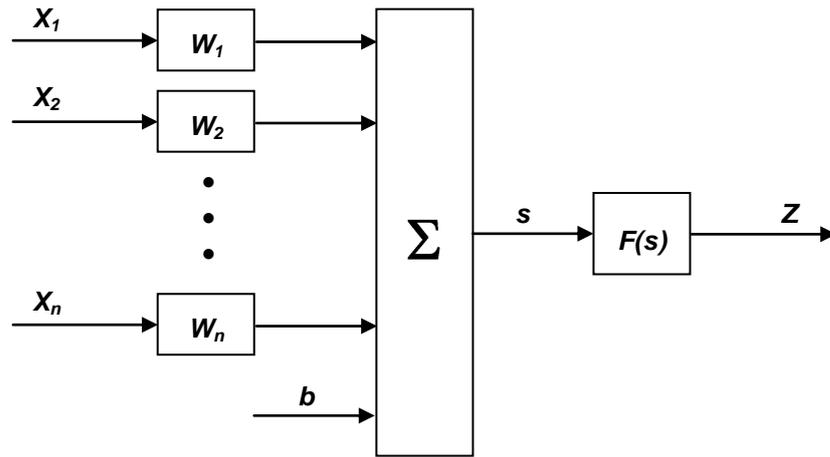
$b$  — постоянное смещение;

$F(s)$  — функция активации, или передаточная функция нейрона.

Обычно в качестве активационной функции используется сигмоид

$$z = F(s) = \frac{1}{1 + \exp(-a \cdot s)}, \tag{1.2}$$

где  $a$  — некоторая положительная постоянная.



Рисунке 1 – Структура искусственного нейрона

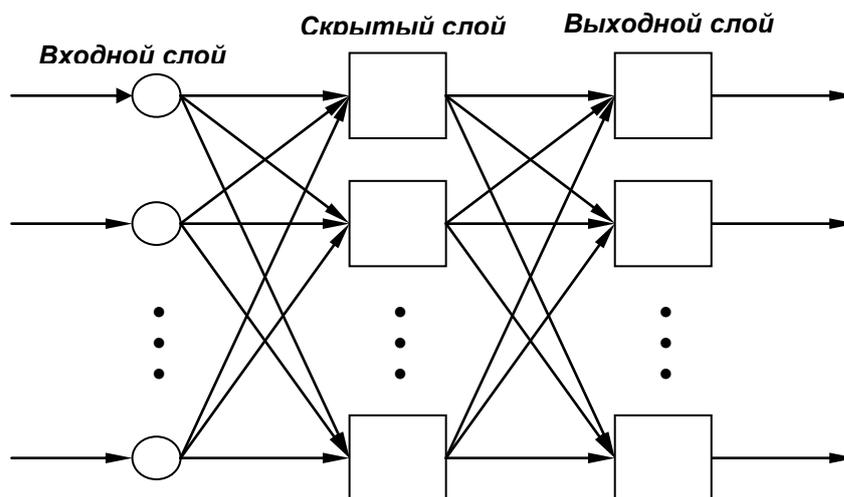
В зависимости от конкретного пакета пользователь может сам выбрать вид этого преобразования (задаваемого в пакете Brain Maker Pro параметрически). В результате получается выходное значение нейрона

$$z = F(x; w), \quad (1.3)$$

Так как обычно несколько нейронов «принимают сигналы» из предыдущего слоя, то набор весов на входе такого  $j$ -го нейрона обозначим  $w_j$ .

Связь между нейронами характеризуется интенсивностью (силой возбуждения), называемой также *синаптическим весом*. Представить их можно в виде синаптической матрицы, элементы которой указывают на силу возбуждения связей между нейронами.

Нейросеть состоит из ряда связанных между собой нейронов, обычно образующих несколько слоёв. На рисунке 2 в качестве примера приведена простейшая двухслойная нейросеть.



Рисунке 2 – Двухслойная нейронная сеть

Отметим, что нейроны первого слева (входного) слоя сети (см. рисунок 2) математических операций не выполняют, а служат лишь для размножения сигналов и при определении числа слоёв не учитываются.

Из искусственных нейронов строится сеть, имеющая определённую архитектуру, которая включает несколько десятков, а иногда сотен или тысяч нейронов, соединённых своими выходами и входами. Веса нейронов будут определять веса соединений («рёбер» сетевой структуры), влияющих на уровень сигнала, распространяющегося по нейросети в виде информационного потока от её входов к выходу.

Наиболее популярной сетевой архитектурой является такая, при которой нейроны каждого слоя непосредственно не взаимодействуют друг с другом и могут быть соединены своими входами-выходами только с расположенными на двух соседних с ними слоях. При этом одна часть нейронов, имеющих лишь по одному входу и выходу в первом слое, используется только для непосредственной обработки входных признаков, а другая — для обработки сигналов, полученных от нейронов из предыдущего, в частности, из первого (см. рисунок 3).

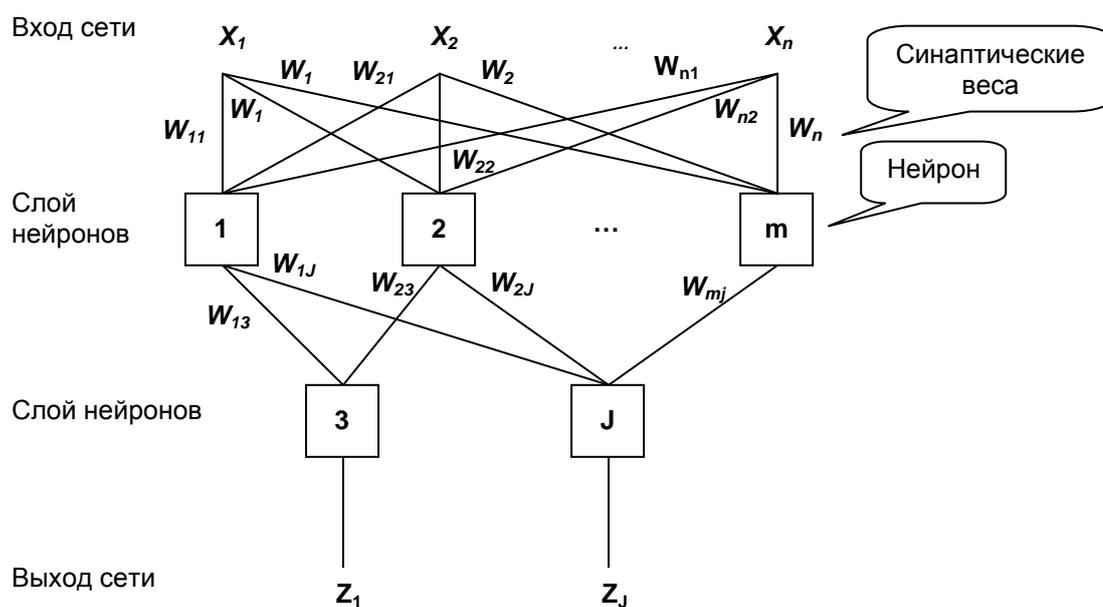


Рисунок 3 – Фрагмент нейронов сети

Выходной слой нейронов используется для формирования результата. Если он содержит один нейрон, то в результате вычислений с помощью нейросети будет получено вещественное число, если же в него входят два нейрона (или более), — то вектор с двумя (или более) компонентами. Например, это могли бы быть минимальная и максимальная цены сделок за торговый день, а также цена закрытия. Результат вычислений по модели, т.е. с помощью сети, часто называют «откликом». Любой слой между входным и выходным — скрытый. В большинстве приложений нейросеть имеет один такой слой. Обычно число нейронов в нём несколько меньше, чем во входном (его называют также сжимающим, поскольку он решает задачу снижения размерности).

Таким образом, модель объекта, реализуемая нейросетью, является, как бы, «черным ящиком», включающим все слои, от входного до выходного, и имеющим обычно много входов (входные нейроны сетевой структуры) и один выход. На вход подаётся набор признаков, описывающих состояние исследуемого объекта (значения его свойств), а на выходе нейросеть выдаёт оценку определяемого свойства (если предварительно зафиксированы веса всех нейронов сети).

По данным экспериментов (специальных наблюдений, испытаний, баз данных и других подобных источников) обычно создаётся таблица с наборами значений признаков и отклика, по которым обязательно заранее настраивают нейросеть. На этом этапе можно

выбрать и архитектуру сети (все нейропакеты позволяют делать это). Пользователя, анализирующего данные и настраивающего нейросеть, называют аналитиком.

Применение нейросетей предполагает выполнение следующих этапов:

- 1) *постановка задачи* — формирование цели применения нейросети (например, прогнозирование курса ценных бумаг);
- 2) *обучение нейросети* — подготовка обучающих примеров, которые представляют собой уже известные результаты решения задачи без нейросети, и предъявление их последней;
- 3) *эксплуатация сети* — сети предъявляется некоторая ситуация, которая либо распознаётся, либо нет.

В качестве примера рассмотрим применение системы поддержки принятия решений (СППР), включающей нейросетевые технологии для краткосрочного прогноза котировок акций РАО «ЕЭС России», обращающихся, в частности, на внебиржевых электронных торгах в Российской торговой системе (РТС). В конце каждого рабочего дня на выходе СППР должны быть данные, которыми трейдер может руководствоваться на утренних торгах в РТС. Такая СППР должна быть удобной в работе, достаточно мощной, с точки зрения аналитических возможностей, а также обеспеченной современным интеллектуальным компонентом. Интеллектуальный компонент включает в себя контекстно-зависимую электронную подсказку (помощь в реальном времени), требующуюся для построения технологической цепочки анализа данных, а также удобное описание методологии построения эффективных математических моделей.

Прогноз для нашего примера выполняется путём оценки попадания цены закрытия торгов РТС в одну из категорий:

- $A$  — цена возрастёт выше, чем на +0,9%;
- $B$  — цена изменится по абсолютной величине меньше, чем на 0,9%;
- $C$  — цена упадёт ниже, чем на -0,9%.

При  $A$  трейдер может утром заключать контракты на покупку акций, при  $C$  — на продажу, а при  $B$  — выйти из торгов акциями РАО «ЕЭС России».

На этапе создания модели проводится обучение, или настройка, нейросети. В её ходе встроенный в нейропакет алгоритм глобальной минимизации находит «числовые весовые коэффициенты, описывающие силу межнейронных связей». *Критерием минимизации является уменьшение квадрата невязки между результатом расчётов по модели и реально наблюдаемой величиной* (в частности приращением цены закрытия акций). Веса фиксируются после завершения работы алгоритма минимизации и на этапе прогноза уже не изменяются. По работе нейросети на независимом наборе данных, который не использовался при её настройке, оценивается качество последней.

Эффективность использования алгоритма глобальной минимизации устанавливается рядом теорем о полноте. Смысл данных теорем сводится к тому, что любая непрерывная функция на замкнутом ограниченном множестве может быть равномерно приближена функциями, вычисленными нейронными сетями, при выполнении некоторых достаточно легко реализуемых условий; таким образом, нейросети являются универсальными аппроксиматорами.

Основным алгоритмом обучения MLP, использующихся в системах управления, является алгоритм обратного распространения. В данном случае нейросеть обучается воспроизводить зависимость, заданную набором из  $N$  пар точек  $\langle x^i, y^i \rangle$ ,  $i = 1, 2, \dots, N$ , с минимизацией суммарной квадратичной ошибки

$$E = \sum_{i=1}^N E_i, \quad (1.4)$$

где  $E_i = (y^i - \theta_i)^2$ ,  $\theta$  — выход сети при поступлении на вход  $x_i$ .

Алгоритм состоит в последовательном выполнении следующих шагов:

1. Задаются параметр  $\eta \in [0, 1]$  и некоторые малые случайные веса сети  $w_j^{(l,k)}$  —  $j$ -й вес  $k$ -го нейрона в  $l$ -м слое нейросети, а также  $E_{max}$  — максимальное значение суммарной функции ошибок сети.

2. Устанавливается  $i = 1$  — номер текущей обучающей точки и  $E = 0$  — текущее значение суммарной функции ошибок сети.

3. Вводится обучающая пара  $x = x^i$  и  $y = y^i$ . Вычисляется выходной сигнал сети  $\theta_i$ .

4. Производится корректировка весов по формуле

$$W^{(l)} = W^{(l)} + \eta \frac{\partial E_i}{\partial W^{(l)}}, \quad (1.5)$$

где  $W^{(l)}$  — матрица весов  $l$ -го слоя нейронов, причём коррекция весов происходит в направлении от последнего слоя к первому, т. е.  $l$  последовательно меняется от  $M$  (число слоев в сети) до 1.

5. Корректируются (наращиваются) значения функции ошибки:

$$E = E + \frac{1}{2} (y^i - \theta_i)^2, \quad (1.6)$$

6. Если  $i < N$ , то  $i = i + 1$  и переход к п. 3.

7. Если  $E > E_{max}$ , то переход к п. 2.

8. Конец.

В формуле (2.5) под  $\frac{\partial E_i}{\partial W^{(l)}}$  — понимается матрица, элементами которой являются

частные производные  $\frac{\partial E_i}{\partial w^{(l,k)}}$ . Элементы данной матрицы в ряде случаев могут быть определены в аналитическом виде. Например, если нейроны сети описываются сигмоидальными функциями вида

$$\theta = \frac{1}{1 + \exp(-w^T x)}, \quad (1.7)$$

где  $\theta$  — выходной сигнал нейрона,  $w$  — вектор весов нейрона,  $x$  — вектор входных сигналов нейрона;

то для выходного нейрона сети

$$\frac{\partial E_i}{\partial W^{(M)}} = -(y^i - \theta_i) \cdot \theta_i \cdot (1 - \theta_i) \cdot \bar{\theta}^{(M-1)}, \quad (1.8)$$

где  $\theta_i$  — выход сети;

$\bar{\theta}^{(M-1)}$  — выходной сигнал  $(M-1)$  слоя.

Для предыдущего слоя нейросети:

$$\frac{\partial E_i}{\partial W^{(M-1,k)}} = -(y^i - \theta_i) \cdot \theta_i \cdot (1 - \theta_i) \cdot W^{(M-1)} \cdot \theta_i^{(M-1,k)} \cdot (1 - \theta_i^{(M-1,k)}) \cdot \bar{\theta}^{(M-2)}, \quad (1.9)$$

где  $\theta_i^{(M-1,k)}$  — выходной сигнал  $k$ -го нейрона  $(M-1)$  слоя;

$\bar{\theta}^{(M-2)}$  — выходной сигнал  $(M-2)$  слоя.

Аналогично для всех остальных слоёв сети.

Если вид частных производных аналитически определить не удастся, то пользуются приближёнными формулами для численной оценки производных:

$$\frac{\partial E_i}{\partial W^{(M)}} = \frac{\Delta E_i}{\Delta W^{(l)}}, \quad (1.10)$$

Рассмотренный алгоритм реализует процедуру градиентного метода наискорейшего спуска. Градиентный алгоритм минимизации неэффективен в вычислительном отношении, особенно для нейросетевой архитектуры с обратным распространением ошибки, принятой в пакете Brain Maker Pro. Данный метод имеет линейную скорость сходимости,

а также резкое замедление оптимизационного процесса в окрестности точки оптимального решения, что делает рассматриваемый алгоритм на практике малоэффективным. Тем не менее, благодаря своей простоте он остаётся одним из наиболее распространённых. Следовательно, требуется, либо наличие мощного процессора в ПК, либо использование для глобальной минимизации генетических алгоритмов.

Важным вопросом при применении многослойных персептронов является выбор структуры сети — числа слоёв сети и числа нейронов в каждом слое. Сеть, содержащая недостаточное количество нейронов, может оказаться недостаточно гибкой для аппроксимации данных с требуемой точностью. В то же время сеть слишком большого объёма будет точно следовать данным из обучающей выборки, но плохо обобщать данные, не входящие в обучающую выборку, такое явление называется *переобучением*. Для решения данной задачи разработаны многочисленные эмпирические формулы, а также алгоритмы адаптации, настраивающие в процессе обучения не только значения весов нейронов, но и структуру сети. Наиболее простым эмпирическим правилом является следующее: число скрытых слоёв многослойного персептрона выбирается 1-2, число нейронов в слое — от  $n$  до  $3n$ , где  $n$  — число входов сети.

Обучение нейронных сетей представляет собой последовательный процесс изменения синаптических весов, отражающих силу возбуждения связей между нейронами. Известны два вида обучения: с «учителем» и самообучение (генетические алгоритмы).

Рассмотрим обучение с «учителем». Предполагается, что некоторая величина  $Z$  зависит от ряда характеристик  $X_1, X_2, \dots, X_n$ . Необходимо обучить нейросеть распознавать некоторое значение  $Z$  при определённых значениях характеристик  $X_1, X_2, \dots, X_n$ . Готовится набор обучающих примеров, которые состоят из набора исходных векторов  $X_1, X_2, \dots, X_n$  и соответствующих им выходных значений  $Z$ . Если, например,  $Z$  — будущая цена акций через три дня, а  $X_1, X_2, \dots, X_n$  — сегодняшние котировки (рыночный курс ценной бумаги) некоторого набора акций, то каждый обучающий пример представляет собой котировки акций на некоторую прошлую дату плюс стоимость акций ( $Z$ ) через три дня после этой даты.

Эти примеры подаются на вход сети.

$X_1$	$X_2$	...	$X_n$	$Z$
$x_{11}$	$x_{12}$	...	$x_{1n}$	$z_1$
$x_{21}$	$x_{22}$	...	$x_{2n}$	$z_2$
$x_{m1}$	$x_{m2}$	...	$x_{mn}$	$z_m$

Вначале на вход подается первая строка. Нейросеть формирует начальную зависимость между  $z_1$  и  $x_{11}, x_{12}, \dots, x_{1n}$ . На основе этой зависимости вычисляется текущее значение  $z_1$ , которое сравнивается с эталонным значением  $z_1$ . Если разница превышает допустимый уровень, то алгоритм обучения изменяет синаптические веса (весовые коэффициенты), после чего эта строка вновь подаётся на вход сети для обучения до тех пор, пока результат не будет удовлетворительным. Затем подаётся следующая строка  $x_{21}, x_{22}, \dots, x_{2n}$  и  $z_2$ . Процесс повторяется до тех пор, пока суммарная ошибка в реакции сети на все строки не станет меньше заданной (см. рисунок 4).

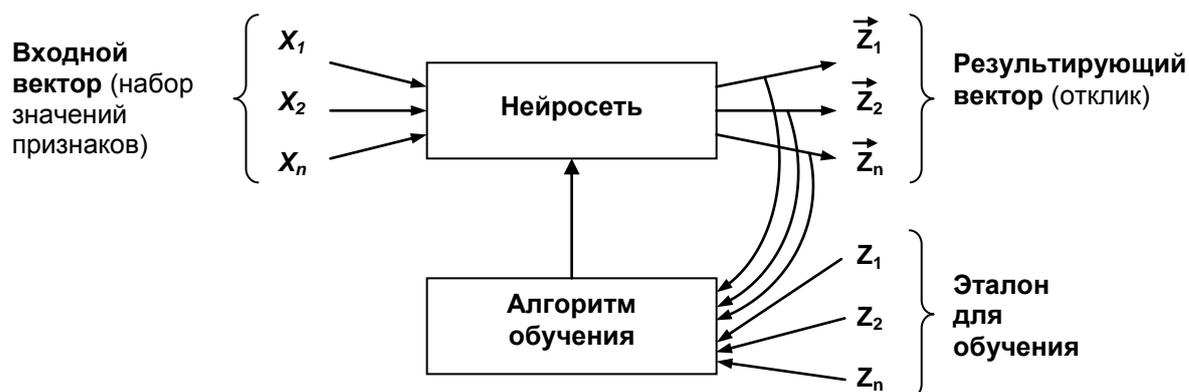


Рисунок 4 – Схема обучения нейросети с «учителем»

На этапе настройки, обычно проводимой градиентными методами, получают числовые веса всех нейронов, принимающих сигналы от нейронов предыдущего слоя. По их набору ( $W_1, \dots, W_j$ ) минимизируется квадратичная функция потерь, которая задаёт штраф между значениями отклика, действительно имевшими место при фиксированных весах и формируемыми нейросетью, причём это выполняется для всех примеров, вошедших в материал обучения.

В результате настройки получается нелинейная модель связи входов и отклика

$$O(x) = F(x; (W_1, \dots, W_j)) \quad (1.10)$$

в виде аппроксимации реальной их связи  $O(x)$ .

В выражении (2.10) через ( $W_1, \dots, W_j$ ) обозначена совокупность всех весовых коэффициентов в нейросети некоторой фиксированной архитектуры. На основе построенной модели можно, подав на её входы набор значений показателей для новых данных, оценивать отклик.

Нейросети являются универсальным средством аппроксимации функции многих переменных  $O(x)$ , поэтому описанный подход позволяет, наряду с применением традиционных моделей многомерной статистики, решать типичные прикладные задачи — классификации, распознавания и прогнозирования.

При использовании нейросетевой технологии работа строится в несколько этапов. Рассмотрим их содержание и важнейшие процедуры.

 *Первым этапом* является *чёткое определение проблемы*, т.е. того, что пользователь-аналитик собирается получить от нейросетевой технологии на выходе. Это может быть некоторый вектор, характеризующий систему или процесс. Например, кривая доходности ГКО; цена отсечения первичного аукциона; показатель целесообразности реструктуризации инвестиционного портфеля, точки перелома тренда и т.п.

 *Вторым этапом* является *определение и подготовка исходных данных* для реализации нейросетевой технологии. При этом отбирается вся необходимая, адекватно и полно описывающая процесс информация. Для наиболее успешного решения проблемы формирования наборов информации для последующего прогнозирования ситуаций рекомендуется привлекать хорошо знающих данную конкретную область специалистов.

Сложность выполнения второго этапа заключается в том, что должен быть соблюден баланс между стремлением увеличить количество входных параметров и вероятностью получить плохо обучаемую сеть, которая может исказить ожидаемые прогнозы. Дело в том, что число дней ретроспективы и прогноза, которые зависят от свойств исследуемых данных, сильно влияют на точность прогноза. Поэтому выбор несоответственно большого числа дней для прогноза или их малого числа ретроспективы может привести к тому, что сеть будет не в состоянии обучаться.

 *Ввод данных в систему, подготовка данных, создание файлов для тренировки и тестирования* можно считать самостоятельным *третьим этапом*. Основной целью

работы на этом этапе является формирование необходимого набора ситуаций, с которыми придётся работать аналитику, а затем распределение исходных данных по этим ситуациям. При этом нейросетевая технология автоматически реализует задачу классификации, в основе которой лежит нечёткая логика. В качестве входных параметров могут быть использованы искусственно созданные характеристики системы, в частности для фондового рынка это могут быть различные индикаторы технического анализа.

На этапе подготовки данных анализируется степень их информационной насыщенности, для чего выявляется степень влияния конкретного параметра на прогнозируемую величину. Достигнув равномерного наполнения всех степеней зависимости, выявляется соответствие между прогнозируемой величиной и параметром в виде «Если..., то...; иначе...», что близко к реализации алгоритма нечёткой логики и экспертным системам.

Современные нейросетевые продукты позволяют работать как с числовыми, так и с текстовыми данными, т.е. преобразовывать набор символов (слово, фраза) в уникальный набор чисел. Нейросетевой пакет *Ward System* делает возможной также обратную операцию, т.е. представление результатов работы нейросети в виде не только чисел, но связного текста, что позволяет генерировать результаты в виде различных информационных сообщений. Правила для обучения нейросети могут задаваться посредством их ввода в готовом виде, а также в виде чисел, требующих дополнительных преобразований данных. Причём эти ограничивающие и разрешающие правила и условия могут задаваться в процессе решения задачи. Другим методом задания правил в нейропакете *Ward System* является работа с индикаторами технического анализа. Включение индикаторов в процесс обучения существенно повышает не только точность прогнозов, но и их стабильность, и статистическую достоверность, что значительно облегчает работу аналитика.

Последними этапами можно считать проведение тестирования нейросети и её запуск для получения прогноза. Работоспособность первоначально обученных сетей проводится на тестовой выборке данных. По результатам тестов отбираются наиболее перспективные варианты. При этом руководствуются тем, что точность и надёжность прогноза, прежде всего, зависят от типа прогнозируемой величины, состояния, в котором находится система (стационарное, вблизи критической точки и т.д.), типа системы (управляемая она извне или замкнутая). Например, наиболее точен и надёжен прогноз локального изменения тренда в стационарном состоянии рынка.

Если результаты тестирования не удовлетворяют, то просматривают набор входных данных, изменяют некоторые учебные программы или перестраивают сеть.

После завершения полного цикла решения задачи возможны два пути: пользоваться в дальнейшей работе созданной системой, что вполне приемлемо для одного специалиста, решающего определённый круг задач, или создать для каждой задачи независимые приложения в виде отдельного файла, который может использоваться другими программами. В этом случае полученный вариант нейросетевой технологии представляет собой *упакованную нейросеть* с описанными функциями передачи данных команд управления.

*Основные достоинства нейросетей:*

- 1) адаптируемость (лёгкая переобучаемость при больших потоках входных данных), а также возможность потенциального распараллеливания вычислений.
- 2) способность обучаться на примерах без программирования, что позволяет отказаться от поиска каких-либо аналитических зависимостей между входными данными и результатами;
- 3) обучение на неполной, противоречивой и искажённой информации;
- 4) не требуют выполнения условия отсутствия взаимосвязи между входными факторами, как это требуется в регрессионном анализе.

К недостаткам нейросетей относятся «непрозрачность» процесса их работы и трудности интерпретации результатов, а также то, что в них, в отличие от экспертных систем с логическим выводом при анализе, приходится приводить исходные данные к цифровой

форме (как и для статистических пакетов). Кроме того, правильно настроенная нейросеть, хотя и может адекватно оценивать сходные ситуации, обычно плохо проводит анализ принципиально новых ситуаций, не представленных ранее примерами в материале обучения.

Следует помнить, что для получения устойчивых нелинейных нейросетевых моделей с хорошими прогностическими свойствами требуется, чтобы объём поступающей на их обучение информации был достаточно велик (т.е. число заданных для обучения примеров существенно превышало число нейронов её входного слоя). При статистическом подходе, не в пример нейросетевому, в подобном случае можно построить доверительные интервалы.

Для эффективного использования нейросетевых технологий необходимо глубоко понимать сущность моделируемого процесса. Практика работы с нейросетевым пакетом *Brain Maker Pro* на российском финансовом рынке свидетельствует о том, что создание и тщательное ведение обширной, постоянно обновляемой и хорошо структурированной базы финансовых, макроэкономических и политических данных жизненно необходимо, поскольку их влияние на ситуацию чрезвычайно велико. Так как база непрерывно изменяется, набор информативных признаков или их порядок внутри этого набора также изменяется во времени. Поэтому нейросеть приходится время от времени настраивать заново. Так как в любом нейропакете есть свои ноу-хау по реализации в нём обучения, аналитику-профессионалу при выполнении прогноза целесообразно работать с двумя или более пакетами, настраивая их на одних и тех же данных.

Любая задача, связанная с использованием финансовых средств на валютном рынке или рынке ценных бумаг, сопряжена с риском и требует тщательного анализа и прогноза. *Точность прогноза, устойчиво достигаемая нейросетевыми технологиями при решении реальных задач, уже превысила 95%*. Поэтому количество примеров успешного применения нейросетевых программных продуктов стремительно растёт.

Среди перспективных направлений использования нейросетевых технологий можно назвать создание компьютерных моделей поведения клиента для оценки риска или перспективности работы с конкретными клиентами. Например, можно проанализировать прежние сделки и на этой основе оценить вероятность того, согласится ли конкретный клиент на то или иное предложение.

На мировом рынке аналитического программного обеспечения представлен широкий спектр нейросетевых технологий, начиная от систем, ориентированных на суперкомпьютеры, стоимость которых превышает 50 тыс. долл., до недорогих (несколько сотен долларов) нейропакетов, работающих на платформе персональных компьютеров и рабочих станций. Это делает доступной технологию нейронных сетей для приложений практически любого уровня.