

Федеральное агентство по образованию РФ

ГОУ ВПО “Уральский Государственный Технический Университет – УПИ”

## **ПРАКТИЧЕСКИЙ НЕЙРОКОМПЬЮТИНГ**

Учебное пособие

Научный редактор – проф., д-р. техн. наук В.И. Кузякин

Екатеринбург  
2005

УДК 004. 383. 8. 032. 26  
ББК 32. 818  
Г 63

Рецензенты:

Кафедра информационных системы в экономике УрГЭУ; г. Екатеринбург (Зав. кафедрой, проф., д-р физ.-мат. наук А.Ф. Шорников); действительный член РАЕН, проф., д-р техн. наук Р.П. Чапцов ( Южно – уральский технический университет, г. Челябинск).

Авторы: С.Л. Гольдштейн, В.Б. Щербатский, О.В. Гущина

ПРАКТИЧЕСКИЙ НЕЙРОКОМПЬЮТИНГ: учеб. пособие  
/ С.Л. Гольдштейн, В.Б. Щербатский, О.В. Гущина. Екатеринбург: ГОУ ВПО УГТУ – УПИ, 2005. 122 с.  
ISBN 5–321–00566–4

Данное учебное пособие рекомендуется студентам технических вузов, прикладным программистам, руководителям информационных отделов предприятий и фирм для практического изучения и реализации методов и алгоритмов программирования нейронных сетей на современных персональных компьютерах. Пособие содержит описание основных проблем нейросетевых систем, примеры 7 постановок технологических задач, состав математического обеспечения, разработки алгоритмов решения и анализа результатов. В пособие также включены фрагменты реальных программ.

Библиогр.: 28 назв. Табл.13. Рис.56.

УДК 004. 383. 8. 032. 26  
ББК 32. 818

ISBN 5–321–00566–4

© ГОУ ВПО “Уральский государственный  
технический университет – УПИ“, 2005  
© С.Л. Гольдштейн, В.Б. Щербатский,  
О.В. Гущина

## О Г Л А В Л Е Н И Е

В в е д е н и е.....	6
1. Методы обработки входных данных и интерпретации результатов в нейронных сетях .....	8
1.1. Главная проблема задач распознавания и классификации. Обсуждение.....	8
1.2. Методы моделирования нейропроцессов при распознавании и классификации.....	9
1.3. Модель составного нейрона в компьютерных программах – эмуляторах.....	12
1.4. Методика определения характеристик ассоциаторов как функций принадлежности.....	15
1.5. Применение экспертных оценок в качестве входной информации для нейронной сети.....	17
1.6. Подготовка и выбор эталонов для обучения нейросети.....	21
1.7. Факторный анализ и получение новых знаний с помощью нейросетей.....	25
1.8. Определение степени компетентности нейросети .....	28
1.9. Контрольные вопросы и задания.....	33
2. Практический нейрокомпьютинг .....	34
2.1. Применение нейросетей в программном комплексе специалиста – технолога.....	35
2.2. Диагностика дефектов производства облицовочной плитки с помощью компьютерной нейросети.....	37
2.2.1. Постановка задачи.....	37
2.2.2. Математическая формулировка задачи диагностики.....	37
2.2.3. Алгоритм решения задачи диагностики.....	39
2.2.4. Синтез нейросети для решения задачи диагностики.....	41
2.2.5. Процесс диагностики нейросетевым методом.....	42
2.3. Диагностика распределения материалов и газов в доменной печи.....	47
2.3.1. Физическая постановка и математическая формулировка задачи диагностики доменного процесса.....	47
2.3.2. Определение параметров нейронной модели.....	50
2.3.3. Применение разработанной нейромодели доменной печи.....	53
2.4. Нейроробот ”Партнёр мастера” для управления комбинированным дутьём доменных печей.....	57
2.4.1. Особенности нейроробота ”Партнёр мастера”.....	57
2.4.2. Основные принципы управления с помощью нейроробота.....	57
2.4.3. Обучение нейроробота ”Партнёр мастера”.....	58

2.4.4. Адаптация нейроробота "Партнёр мастера" .....	60
2.4.5. Результаты применения нейроробота на доменных печах.....	61
2.4.6. Состав и реализация программного обеспечения нейроробота.....	63
2.5. Нейроуправление пусковыми режимами технологических объектов большой единичной мощности.....	66
2.5.1. Нейронная модель для пуска технологического оборудования.....	66
2.5.2. Характеристика i-модели (нейрона).....	67
2.5.3. Расчёт связей между нейронами.....	70
2.5.4. Задание исходного состояния сети.....	71
2.5.5. Расчет оптимального переходного процесса .....	72
2.6. Моделирование систем автоматического регулирования (САР) и автоматизированных систем управления (АСУ ТП) с помощью нейросетей.....	75
2.6.1. Обучение сети.....	77
2.6.2. Применение сети.....	79
2.6.3. Рекомендации пользователю для работы с файлами NNDT.....	80
2.6.4. Пример реализации расчета переходного процесса нейромодели апериодического звена (1-го порядка).....	80
2.6.5. Параметры нейромоделей типовых звеньев.....	82
2.7. Применение нейросетей на фондовом рынке .....	88
2.7.1. Особенности функционирования и отличия нейроробота "Уникомпартнёр".....	88
2.7.2. Подготовка входной информации для нейроробота "Уникомпартнёр".....	89
2.7.3. Компьютерная формализация "новостного фона".....	96
2.7.4. Обучение нейроробота "Уникомпартнёр" и нейродиагностика рынка ценных бумаг.....	103
2.7.5. Алгоритм функционирования нейроробота "Уникомпартнёр".....	105
2.7.6. Факторный анализ рыночной позиции трейдера с помощью нейроробота.....	105
2.7.7. Работа нейроробота во время дневной торговой сессии.....	108
2.8. Определение оптимальной цены продукции с помощью нейромаркетингового исследования.....	110
2.8.1. Предлагаемый метод определения оптимальной цены на облицовочную плитку.....	110
2.8.2. Реализация предлагаемого метода определения оптимальной цены .....	111
2.8.3. Методика оценки влияния разницы в себестоимости на оптимальную рыночную цену.....	114

2.8.4. Анализ оптимальной цены с учётом художественной ценности, дизайна коллекций и разницы себестоимости.....	115
2.9. Контрольные вопросы и задания.....	119
З а к л ю ч е н и е .....	120
Библиографический список .....	121

## В в е д е н и е

В настоящее время наблюдается повышенный интерес к нейронным сетям, которые успешно применяются в различных областях профессиональной деятельности для решения задач прогнозирования, классификации и управления. Богатые возможности, простота в использовании нейросетей отражаются в многочисленных теоретических исследованиях по этой теме [1,2]. В них отмечается, что вначале основной областью исследований по искусственному интеллекту были экспертные системы [3]. Скоро стало ясно, что подобные системы, хотя и приносят пользу, не охватывают ключевые аспекты работы человеческого мозга. Причина этого состоит в том, что они не в состоянии адекватно воспроизвести структуру мозга. Чтобы в будущем создать искусственный интеллект, необходимо строить вычислительные системы с похожей архитектурой.

Практическая реализация нейросетей на нейрокомпьютерах или обычных компьютерах с помощью программ-эмуляторов основана на сравнительно простых моделях нейронов. Не учитываются нелинейность суммации, время задержки сигналов, эффекты синхронизации, частотная модуляция, рефрактерность. Имеются проблемы и неясности в методах обработки сигналов нейросетевыми технологиями, связанные с интуитивным выбором переменных и отбором данных, представлением экспертной информации, интерпретацией результатов и оценкой точности работы нейросети. В итоге практические результаты, по сравнению с теоретическими исследованиями, выглядят не столь впечатляющими. Повторить опубликованные примеры работы нейросетей часто в состоянии только их авторы.

Материалы настоящего пособия посвящены решению именно практических задач в технологических процессах различных областей с целью демонстрации эффективности, преимуществ нейросетей и распространения положительного опыта их применения.

Для достижения этой цели вначале рассмотрены основные методы обработки входных данных и интерпретации результатов расчета в нейросетях. Эти методы разработаны как на основе совершенствования известных способов, так и в результате собственных исследований нейросетевых технологий, ведущихся на кафедре вычислительной техники УГТУ–УПИ. Далее приведены конкретные примеры реализации нейросетей в промышленности и на рынке. В примерах присутствуют описания необходимых подробностей преобразования информации, играющие решающую роль для успешного обучения и работы нейросети.

Обширный экспериментальный материал для нейрокомпьютинга был получен при содействии широкого круга предприятий и организаций. В связи с этим авторы выражают свою благодарность и признательность за оказанную помощь следующим сотрудникам: проф., д-р техн. наук Ю.В. Федулову, канд. техн. наук М.Ф. Сафронову, В.А. Краснобаеву, С.П. Рогожникову (ОАО “ММК”); А.Ю. Чернавину, Д.Н. Волкову, В.В. Филлипову, И.В. Суковатину (ОАО “НТМК”, ОАО “Серовский металлургический завод”); д-р техн. наук Б.А. Боковикову (НПВП “ТОРЭКС”); д-р техн. наук А.Н. Дмитриеву (Институт металлургии УО РАН); А. Бобкову, Д. Казину (компания “Аккорд-Инвест”, инвестиционная финансовая компания “Уником Партнер”); А.Г. Закалиной (информационные системы управления растущим бизнесом “НАУМЕН”); А.В. Хмелеву (Екатеринбургский завод керамических изделий); А.В. Караулову (ЗАО “Галактика-Урал”); Заслуженному деятелю науки и техники РФ, действительному члену АИН РФ, проф., д-р техн. наук В.Г. Лисиенко, член-корр., АИН РФ, проф., д-р техн. наук Ю.Н. Овчинникову, проф., д-р техн. наук И.Д. Кашееву, доц., канд. техн. наук Н.А. Михайловой, доц., канд. техн. наук Б.А. Фетисову (ГОУ ВПО “УГТУ–УПИ”); канд. техн. наук В.М. Кормышеву (РЦ НИТ ГОУ ВПО “УГТУ–УПИ”).

Авторы также благодарят всех аспирантов и студентов ГОУ ВПО “УГТУ–УПИ”, принявших участие в программной реализации, проведении расчетов и оформлении результатов нейрокомпьютинга в процессе изучения курсов “Параллельные системы и нейрокомпьютинг”, “Методы технической диагностики”, “Информатика” и других дисциплин.

# **1. Методы обработки входных данных и интерпретации результатов в нейронных сетях**

## **1.1. Главная проблема задач распознавания и классификации. Обсуждение**

Широкий спектр информационных технологических задач относится к задачам распознавания образов, общей ключевой проблемой которых является выделение полезного сигнала на фоне шума. Информационный шум на производстве возникает вследствие колебаний параметров сырья, флуктуаций в самом технологическом объекте, из-за изменения внешних условий и недостаточной компетентности обслуживающего персонала. Так как нейронные сети более всего похожи на математические модели процессов типа “черного ящика” (но не являются их аналогами!), то их применение прежде всего связано с известными статистическими методами обработки выбросов, определения частоты и числа наблюдений, критериями их классификации. В последних все сводится к вычислению границ распознавания “свой–чужой”, “годен–не годен” и т.п. Если мощность полезного сигнала по сравнению с производственными шумами велика (более 30 дБ), то вычисление критериев классификации практически любыми методами не представляет затруднений и распознавание технологической ситуации (ТС) происходит однозначно и с высокой степенью вероятности (более 0,9). Другое дело, если мощность сигнала сравнима с мощностью шума. Например, в статистической радиотехнике рассматривается некоторое пороговое значение отношения мощностей сигнал/шум (С/Ш), равное 1 и характеризующееся величиной корреляционной связи между входным и выходным сигналами, соответствующей 0,707. Доказывается, что ниже этого порога распознавание или обнаружение не гарантируется [4]. Построение для этой цели сложных и дорогих корреляционных фильтров в некоторых случаях повышает указанное соотношение, но одновременно порождает другие проблемы, связанные с необходимостью длительного наблюдения полезного сигнала, параметры которого при наблюдении не должны изменяться. Как правило, технологические процессы в промышленных объектах имеют высокие производственные шумы и по своей природе нестационарны, поэтому проводить на них такие наблюдения не представляется возможным.

Перечисленные особенности полностью переносятся на функционирование нейронных сетей. Хотя нейронные сети в целом устойчивы к шумам, однако у этой устойчивости есть предел. Например,



выбросы, т.е. значения, не принадлежащие к выборке исходных данных некоторой переменной, поданной на вход нейросети, могут исказить результаты и вызвать ошибку обучения. По этому поводу академик О.И. Ларичев [5] отметил, что ошибка ошибке рознь. Особенно опасны те ошибки, которые совершаются у самой границы, так как они меняют её вид. В экспертных системах классификации на распознавание граничных элементов тратится в 2-3 раза больше времени, чем на классификацию состояния объектов, находящихся внутри класса. Если не предпринимать специальных мер по обработке шумящей информации перед тем как её подавать на входы суммирующих элементов нейросети, то последняя теряет свои преимущества в решении задач распознавания перед обычными статистическими методами.

## **1.2. Методы моделирования нейропроцессов при распознавании и классификации**

Известно существенное преимущество человека перед машиной при обнаружении и классификации сигналов в условиях сильных помех [6]. Так речь может быть разборчивой в таких зашумленных помещениях, как салон самолета или кабина такси. Разборчивость сохраняется даже при наличии всего двух уровней сигнала ( $<0$  и  $>0$ ), когда имеет место явление “клиппирования” речи.

При зрительной идентификации человеком объектов шум иногда играет даже положительную роль. Так глаз имеет повышенную чувствительность к границам участков с одинаковыми уровнями квантования сигнала, например, при передаче таких изображений, как небо, где яркость и цвет меняются плавно. Уменьшить нежелательное влияние таких границ можно путем введения в квантуемое изображение небольшого по уровню шума – “снега”. Хотя полная ошибка квантования при этом увеличивается раза в два, но визуальное восприятие улучшается в результате расплывания границ. Данная методика нечеткой обработки сигнала применена, например, в интеллектуальных модулях телевизионных приемников фирмы “PHILIPS”.

В реальной жизни при распознавании сигналов человеком, пороговая граница соотношения мощностей сигнал/шум снижается до значений, меньших 1. В качестве примера приведем изображение сигналов в виде импульсов прямоугольной (рис. 1.1,а) и прямолинейной (рис. 1.1,б) формы при критическом соотношении мощностей сигнал/шум. При рассмотрении этих изображений зрительно без труда устанавливаются наличие импульса между отметками времени, равными 41 и 61 мин и линейная форма тренда, в то время как для математических моделей и систем распознавания без участия оператора эта задача является пока неразрешимой.

а



б



Рис. 1.1. Примеры типичных сигналов в технологических процессах:  
а – П-образный импульс управления; б – линейный тренд

Современные представления об информационных процессах, происходящих в человеческом мозге учитывают их ассоциативный характер, поэтому при построении математических моделей для компьютерного моделирования и решения задач классификации и распознавания также предусматривают ассоциативные операции с информацией в виде информационных гранул – чанков (chunk) [5]. Чанки – элементы знаний с четкими смысловыми границами (1 бит, слово, образ) извлекаются (актуализируются) из долговременной памяти в кратковременную (оперативную) память, где соотносятся с оперативной информацией, поступающей с объекта также в виде элементарных единиц информации, которые человек способен сразу и целиком распознать, закодировать и запомнить. Объем оперативной памяти невелик, составляет  $7 \pm 2$  чанков, поэтому способности специалиста к распознаванию технологических ситуаций всецело определяются знаниями (образами, понятиями и решающими правилами) об объекте, хранящимися в долговременной памяти. Выбор того, какие именно чанки следует извлечь из долговременной памяти

(прошлого опыта) в виде эталонов для сопоставления носит интуитивный характер и по законам ассоциаций происходит на подсознательном уровне. Поэтому эти знания не могут быть в полной мере вербализованы и использованы в математических моделях или базах знаний экспертных систем.

Нейронные поля в этом плане имеют больше возможностей. Соединения ассоциативных элементов, роль которых выполняют нелинейные элементы – нейроны, формируют как идентифицируемые объекты в виде кластеров, так и границы распознавания, которые имеют нечеткий характер. В процессе обучения человека происходит запоминание – перенесение из кратковременной памяти в долговременную – как свойств задействованных нейронов с их синапсами, так и характеристик входных элементов – рецепторов, с входными каналами связи нейронов. При математическом описании работы и обучения нейросети это соответствует моделированию нечетких ассоциативных границ, например, путем представления активационной функции нейрона в виде функции принадлежности (ФП) [7]. ФП – функция, определяющая степень вероятности принадлежности параметра к тому или иному понятию. Однако пока не существует ответов на вопросы о том, какой вид должна иметь ФП, т.е. быть разной или одинаковой формы для нейронов промежуточных слоев, как должно осуществляться обучение таких нейросетей.

Для решения задачи распознавания в 1957 г. Ф. Розенблатт [8] создал перцептрон, содержащий 3 слоя элементов. В этой конструкции 2-ой, промежуточный слой, нейронов содержал модели ассоциативных элементов. Однако их характеристики отдельно не определялись, а обучение перцептрона происходило путем изменения весов связей выходного нейрона. Ничего не было предусмотрено и для повышения помехоустойчивости нейросети, так как входная информация поступала прямо на рецепторы перцептрона. В итоге трехслойный перцептрон был способен решать только простые задачи. Для преодоления этой ограниченности обратили внимание на многослойную конструкцию нейросети, предназначенную для моделирования процессов заданной сложности. Однако научный поиск оптимального количества слоев нейронов и их характеристик продолжается по настоящее время, а достигнутые результаты невелики и основываются в основном на эвристических приемах программирования.

Академик Н.М. Амосов [9] предложил нейроструктуры рассматривать как активные семантические сети моделей (М-сети). Принцип работы такой нейросети основывался на том, что в каждый дискретный момент времени  $t$  состояние М-сети может быть описано распределением возбуждений её узлов. Далее применяли специальную процедуру пересчёта для отображения состояния М-сети на её последующее или конечное состояние в момент  $t + 1$ . Впервые такая динамическая нейросеть была практически реализована для целей управления нейророботом “Спиди”. Нововведением А.Н. Амосова являлось также то, что промежуточные нейроны конкретно предназначались

для моделирования эмоций и чувств (страха, уверенности, риска и т.п.) на основе ассоциаций. Обучение нейроробота “Спиди” происходило путем задания матрицы весов связей между нейронами, обеспечивающей в целом заданный уровень “смелости” или “осторожности” при выполнении нейророботом отданного приказа на действие. В первоначальный этап обучения “Спиди” входило также построение передаточных характеристик сенсоров нейроробота, которые в дальнейшем не изменялись. К сожалению, в России это направление, связанное с представлением нейросети как детерминированной модели, не получило развитие и было забыто.

### 1.3. Модель составного нейрона в компьютерных программах – эмуляторах

Повысить до необходимого уровня шумовую помехозащищенность нейросетей, реализуемых на стандартном программном обеспечении и получить удовлетворительные результаты по распознаванию ТС на реальных технологических объектах возможно путем совместного применения ассоциативной фильтрации и суммирования сигналов с дополнительных информационных входов. В качестве примера рассмотрим механизм обработки информации с использованием множественной корреляции, который реализуется в схеме составного нейрона, предназначенного для распознавания изображения цветных объектов. Схема построена на основе информационной теории цветного человеческого зрения и приведена на рис.1.2.

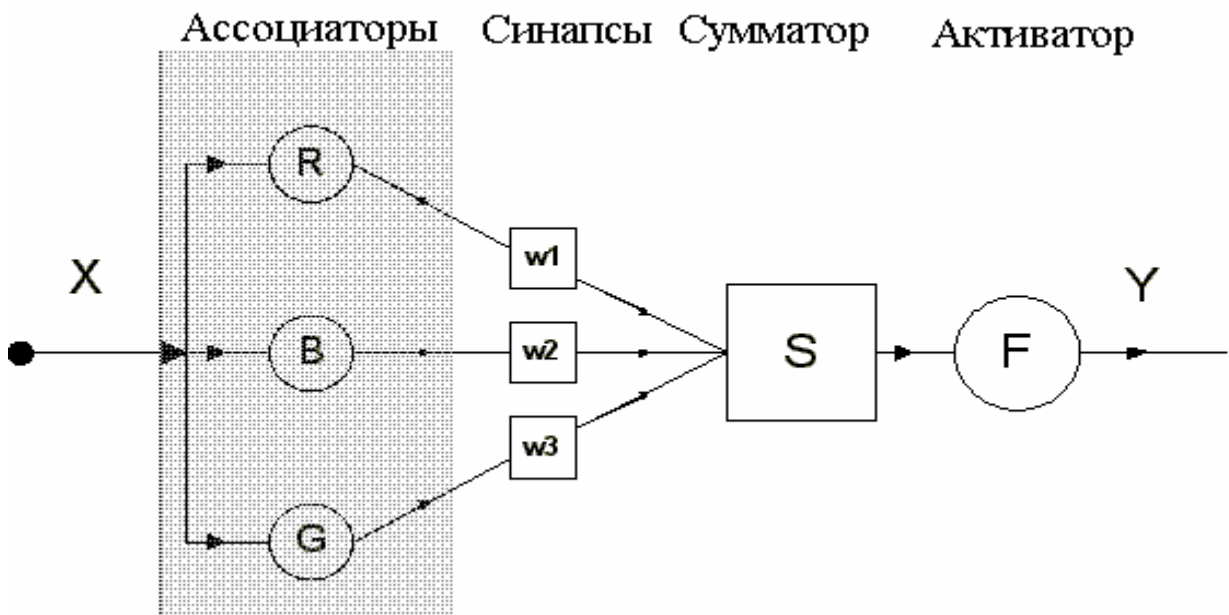


Рис. 1.2. Составной нейрон

Зрительный нейрон содержит синапсы с величиной связей  $W_i$ , сумматор  $S$ , нелинейный активатор  $F$ . Он осуществляет преобразование вектора входного сигнала яркости  $X$  в электрический импульс  $Y$ , который изменяется при сканировании глазом изображения. Отличительной особенностью модели составного нейрона по сравнению с обычной структурой является наличие на входе слоя ассоциаторов красного (R), зеленого (G), синего (B) цвета с передаточными характеристиками в виде ФП. Составной нейрон применяется на входе нейросети и его ассоциаторы выполняют роль нечетких фильтров информации, поступающей от дополнительных информационных каналов. Такой дополнительной информацией, наряду с сигналом яркости  $Y$ , в данном случае являются сигналы цветности R,G,B.

Спектральные характеристики глаза хорошо изучены, поэтому определение на их основе ФП ассоциаторов не представляет трудностей. Вид ФП, рассчитанный и построенный с помощью компьютерной программы, реализованной в Excel показан на рис. 1.3.




Рис. 1.3. Характеристики ассоциаторов R, G, B как функции принадлежности

Выбор формы ФП обеспечивает полосовую фильтрацию помех в каналах сигналов R, G, B и, тем самым, эффективное подавление мультиколлинеарности (межканальной корреляции), которая представляет нежелательное явление в рассматриваемом механизме множественной корреляции.

Эффективность применения ассоциаторов покажем на примере расчета множественной корреляции основного сигнала  $Y$  с сигналами цветности  $R$ ,  $G$ ,  $B$ . Методика расчета известна и состоит в определении коэффициента множественной корреляции  $R_{y/rgb}$  по заданным значениям локальных коэффициентов корреляции между сигналами  $r_{ij}$ :

$$R_{y/rgb} = (1 - \Delta/\Delta_{11})^{0,5}, \quad (1.1)$$

где  $\Delta$  – определитель (4X4) – мерной корреляционной матрицы,

$$\Delta = \begin{vmatrix} 1 & r_{yr} & r_{yg} & r_{yb} \\ r_{ry} & 1 & r_{rg} & r_{rb} \\ r_{gy} & r_{gr} & 1 & r_{gb} \\ r_{by} & r_{br} & r_{bg} & 1 \end{vmatrix} ; \quad (1.2)$$

$\Delta_{11}$  – определитель, получаемый из  $\Delta$  вычеркиванием первой строки и первого столбца.

В качестве исходных условий расчета в этом примере покажем, что мощность шума равна мощности входных сигналов ( $C/\Pi = 1$ ,  $R_{y/i} = 0,707$ ), а характеристики ассоциаторов обеспечивают подавление посторонних сигналов на уровне, при котором взаимные коэффициенты корреляции  $r_{ij}$  не превышают 0,25. Таким образом задается, что при использовании для распознавания только одного какого-либо сигнала, объекты неразличимы.


Эффект от применения всех сигналов получаем, подставляя в определители исходные данные для расчета множественной корреляции. В этом случае значение коэффициента  $R_{y/rgb} = 0,999$ , что соответствует подавлению шумов на уровне более 35 дБ и, следовательно, надежному распознаванию объекта составным нейроном.

Рассмотренный пример показывает целесообразность применения составных нейронов не только для зрительного распознавания изображений. В сложных технологических объектах также возможно выделение новых информационных каналов и применение множественной корреляции для распознавания ТС.

Таким образом, при обработке технологической информации с помощью нейросетей на их входе следует применять составные нейроны с ассоциаторами.

## 1.4. Методика определения характеристик ассоциаторов как функций принадлежности

Вид ФП задается экспертом-технологом и может быть произвольным. Например, для входных параметров в технологических процессах целесообразно принимать следующие формы ФП [7]:



В качестве исходной используют ФП нейтрального характера, описываемую кривой вероятности погрешности Гаусса. Построение ФП удобно производить в Excel, применяя вначале функцию “Частота” для расчета гистограммы распределения выбранного технологического параметра (например, температуры в обжиговой печи), а затем, ориентируясь на внешний вид полученной гистограммы, производить синтез ФП по алгоритму, сочетающему вычислительные и графические возможности электронных таблиц (рис. 1.4).

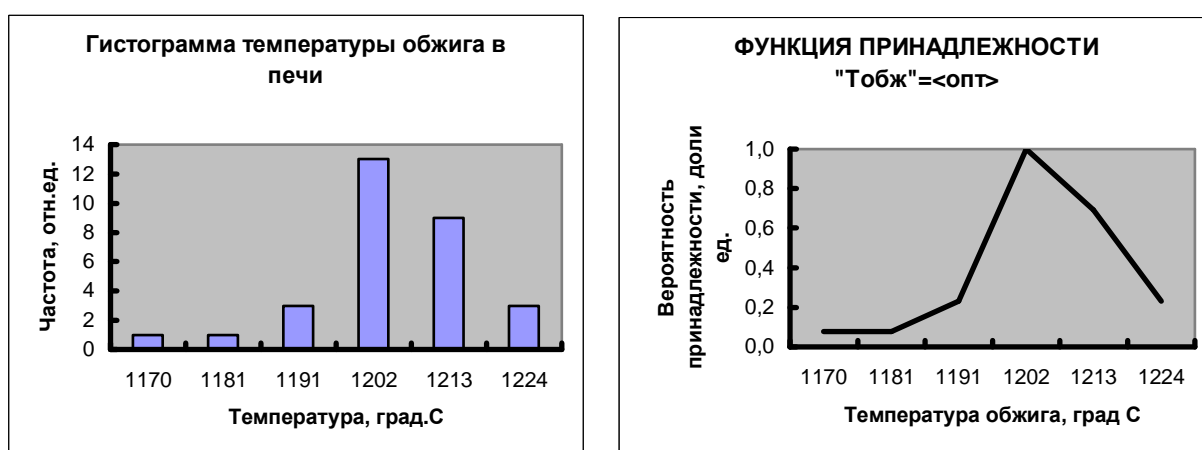


Рис. 1.4. Гистограмма ТП “Температура обжига” и соответствующая ей ФП

В соответствии с возможностями Excel методика определения ФП состоит в следующем.

Формируется исходная таблица расчета базовой ФП, описывающей лингвистические переменные <нзк>, <опт>, <вск> (<мал>, <опт>, <блш>). Фрагмент таблицы представлен ниже. В ней обозначено:

A	B	C	D
№ п/п	X <sub>исх</sub>	X <sub>эксп</sub>	ФП=<нзк>
1	0	0	1,0
2	0,025	0,025	-
3	0,05	0,05	-
4	0,075	0,075	-
5	0,1	0,1	-
-	-	-	-
M	0,5	0,5	-
-	-	-	-
-	-	-	-
-	-	-	-
N	1,0	1,0	0,0

X<sub>исх</sub> – исходные значения технологического параметра (ТП) в нормализованной форме, заданные шагом 0,025;

X<sub>эксп</sub> – значения ТП, заданные экспертом; ФП = <нзк> – значения ФП, соответствующие лингвистической переменной <нзк>.

Значения ФП выводятся также в графической форме. Для коррекции экспертом кривой ФП на графике, что более удобно, используется механизм Excel динамической связи данных, автоматически изменяющий значения в ячейках таблицы, при изменении

положения координат точек на графике. Поэтому, если эксперта по какой-либо причине не устраивает вид ФП, предлагаемый в исходном варианте, он, согласно правилам работы с диаграммой Excel, может изменить форму графика ФП по своему усмотрению. При этом происходит синхронный пересчет табличных значений ФП.

Исходные значения ФП рассчитывают по формулам, обеспечивающим оптимальные условия распознавания технологических ситуаций нейросетью в случае использования кривой Гаусса.

$$\text{ФП } \langle \text{нзк} \rangle = \text{EXP} (-10 X_{\text{эксп}}^2); \quad (1.3)$$

$$\text{ФП } \langle \text{опт} \rangle = \text{EXP} (-10 (X_{\text{эксп}} - 0,5)^2); \quad (1.4)$$

$$\text{ФП } \langle \text{вск} \rangle = \text{EXP} (-10 (X_{\text{эксп}} - 1,0)^2). \quad (1.5)$$

В представленной версии методики предусмотрена возможность экспертного задания ФП указанных видов для всех используемых ТП. Сформированные таким образом ФП далее применяются для определения входных сигналов нейросети по текущим значениям ТП в ассоциаторах.

Алгоритм расчета входных сигналов состоит в следующем:

- определяется нормализованное значение ТП:

$$X_{\text{отн}} = (X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}}), \quad (1.6)$$

где X – текущее значение ТП,

а X<sub>min</sub>, X<sub>max</sub> – минимальное и максимальное значения ТП, заданное экспертом в выбранном диапазоне изменения ФП соответственно;

- найденное значение X<sub>отн</sub> ставится в соответствии с табличной величиной X<sub>эксп</sub>, заданной экспертом;
- определяется значение ФП, соответствующее установленному X<sub>эксп</sub>.



С целью реализации двух последних пунктов разработанного алгоритма составляются формулы Excel, предусматривающие необходимые логические операции. Данные формулы учитывают монотонно возрастающий (убывающий) характер ФП = <вск>, (ФП = <нзк>) и экстремальный характер ФП = <опт>.

Для ФП = <нзк>:

$$B1 = \text{Если } (A1 \leq C1; D1; 0);$$

-----

$$BN = \text{Если } (A1 \leq CN; DN; 0);$$

$$D1 = \text{МАКС } (B1 : BN).$$

Для ФП = <вск>:

$$B1 = \text{Если } (A1 \geq C1; D1; 0);$$

-----

$$BN = \text{Если } (A1 \geq CN; DN; 0);$$

$$D1 = \text{МАКС } (B1 : BN).$$

Для ФП = <опт>:

$$B1 = \text{Если } (A1 \geq C1; D1; 0);$$

-----

$$BM = \text{Если } (A1 \geq CM; DM; 0);$$

-----

$$BN = \text{Если } (A1 \leq CN; DN; 0);$$

$$D1 = \text{Если } (A1 \leq 0,5; \text{МАКС } (B1 : BM); \text{МАКС } (BM : BN)).$$

Здесь текущее значение ТП, равное  $X_{\text{отн}}$ , помещается в ячейку A1, далее в ячейках B1 – BN производится сравнение  $X_{\text{отн}}$  с дискретными табличными значениями  $X_{\text{эсп}}$  и выдаются значения ФП, содержащиеся в ячейках D1 – DN.

В ячейку D1 помещается найденное значение ФП\*, соответствующее условию  $X_{\text{отн}} = X_{\text{эсп}}$ . Определенная таким образом величина ФП\* используется далее как входная величина ТП для синапсов нейросети. Описанный алгоритм легко тиражируется в Excel согласно необходимому количеству входных ТП в решаемой с помощью нейросети вычислительной задаче.

## **1.5. Применение экспертных оценок в качестве входной информации для нейронной сети**

Перспективным направлением в информационных технологиях являются методы экспертного оценивания, используемые в виде человеко-машинных процедур нового поколения [10]. Однако известные методы

экспертных оценок имеют существенные недостатки, ограничивающие область его применения в нейронных сетях. Например, изменение числа рассматриваемых вариантов может также изменить предпочтения специалиста, что не учитывается при обработке экспертных данных компьютером, а существующий математический аппарат выбора альтернатив не дает выхода на общеизвестные характеристики качества (относительную погрешность, достигнутый класс точности и пр.) результатов экспертизы.

Разработанный в УГТУ-УПИ метод экспертного оценивания с применением ПЭВМ сочетает в себе известные положения теории выбора и принятия решений [5] с расчетом объективных характеристик компетентности специалиста, непосредственно проводящего экспертизу [11]. Это отличает предлагаемую человеко-машинную процедуру от известных ранее способов обработки экспертных оценок технологических ситуаций и повышает надежность и достоверность результатов экспертизы. Результаты получаются в виде нормированных величин, являющих входными сигналами для нейросети. Процедура основана на математической модели экспертного оценивания, представленной следующей системой уравнений:

$$\begin{aligned}
 A &= \{ A_1, A_2, \dots A_i, \dots A_k \}; \\
 K &= \{ K_1, K_2, \dots K_j, \dots K_m \}; \\
 \Phi K &\geq \langle D \rangle; \\
 KЭ &= \| a_{ij} \|_{m \times m}; \\
 AЭ &= \| b_{ij} \|_{k \times k}; \\
 D &= \| D_{ij} \|_{k \times m}; \\
 d &= \{ a_1, a_2, \dots a_m \}; \\
 w &= D \times d; \\
 S &= \max \{ S_i \}; \\
 &i = 1, k.
 \end{aligned}
 \tag{1.7}$$

- Здесь
- A – множество альтернатив;
  - K – множество критериев;
  - ΦK – функция компетентности эксперта;
  - D – лингвистическая переменная “Достаточная”;
  - KЭ – матрица экспертных оценок весов признаков  $a_{ij}$ ;
  - AЭ – матрица экспертных оценок степени пригодности  $b_{ij}$  альтернативы  $A_i$  по критерию  $K_j$ ;
  - D – матрица относительных весов  $D_{ij}$  альтернатив по каждому критерию;
  - d – собственный вектор матрицы KЭ;
  - w – вектор взвешенных сумм экспертных оценок для множества A;
  - S – взвешенная сумма экспертных оценок наилучшей альтернативы.

Решение данной системы уравнений осуществляется согласно алгоритму, представленному на рис. 1.5, и реализовано, например, в компьютерной программе “Эксперт-проект”, разработанной на кафедре вычислительной техники УГТУ–УПИ в системе Excel.

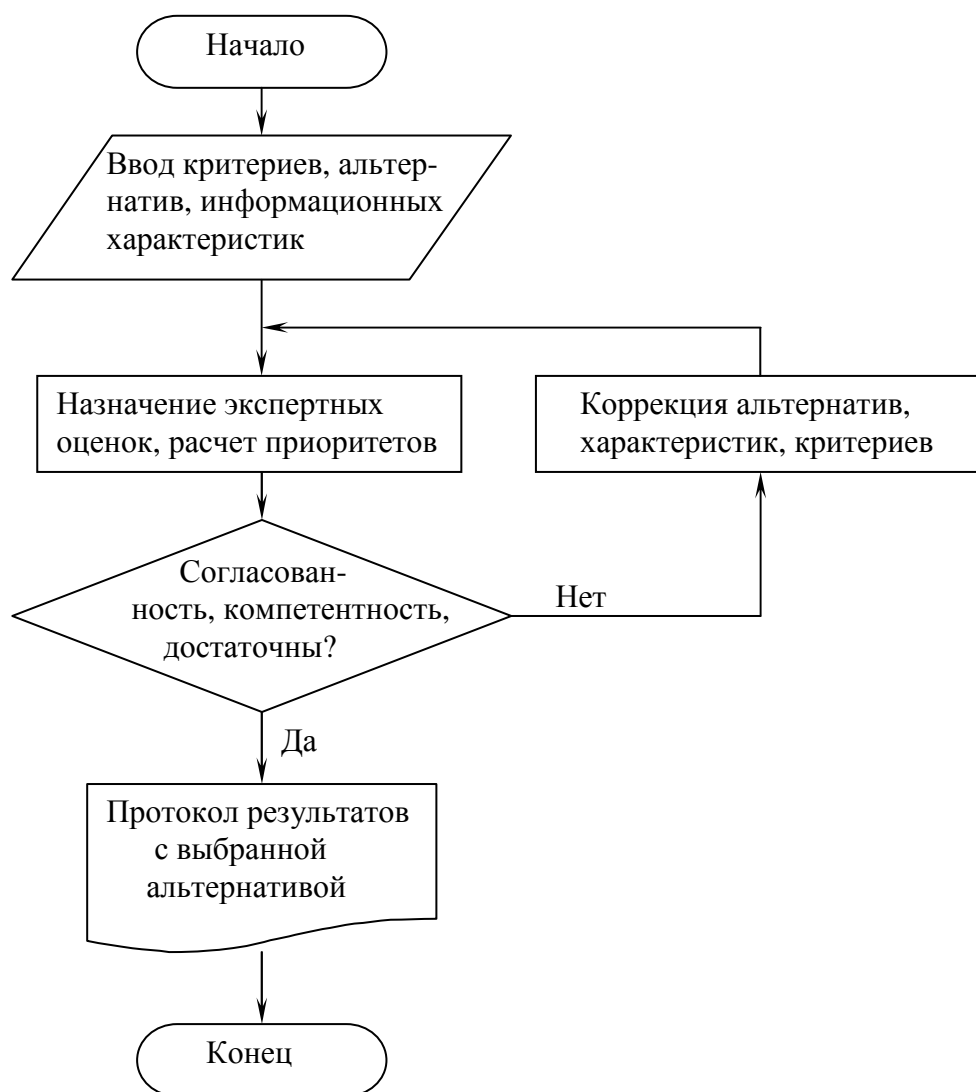


Рис.1.5. Алгоритм обработки экспертных оценок для нейросети

Результатом работы алгоритма являются нормированные значения оценок глобальных приоритетов альтернатив и распределения возможностей относительно наилучшей альтернативы.

Что необходимо учитывать при подготовке входных данных в виде экспертных оценок для нейросети?

Экспертное оценивание включает важный этап формализации качественных характеристик, часто имеющих место в творческой деятельности специалиста. Эти характеристики задаются на основе опыта, интуиции и квалификации эксперта. Формализация осуществляется путем перевода в баллы лингвистических переменных, используемых для сравнения вариантов:

“лучше – хуже”,  
“менее – более”,  
“примерно одинаково” и т.д.

Поэтому компьютерную программу, эмулирующую работу нейросети следует рассматривать как эффективное дополнение к традиционным методам и приемам обработки качественной информации. Однако в связи с этим не только упрощаются, но, наоборот, повышаются требования к подготовке первичной информации на этапе, предшествующей экспертизе.

Некорректно собранная информация затрудняет операцию назначения баллов экспертом, в результате чего степень согласованности оценок может быть недостаточной.

Неудачный выбор критериев и альтернатив не позволяет найти достаточно сильные отличия в них, выражаемые числом различных экспертом градаций и получить необходимую точность экспертизы. Указанное имеет прямое отношение к степени компетентности специалиста, подготавливающего информационное обеспечение и проводящего экспертизу.

Подготовка информационного обеспечения в производственных условиях должна включать следующие типовые мероприятия:

- рассмотрение технологических схем действующих процессов и их оборудования для выбора альтернатив;
- подбор критериев и их информационных характеристик для последующего сравнения;
- оценка новизны: видов сырья; машин и аппаратов; методов обработки сырья и подготовки полуфабрикатов;
- рассмотрение способов механизации и автоматизации отдельных технологических и транспортных операций, линий цехов.

Надежность результатов экспертизы должна подтверждаться метрологическими характеристиками, найденными на основе информационной теории вероятностей и ошибок и являющимися, вследствие этого, объективными показателями компетентности эксперта.

## 1.6. Подготовка и выбор эталонов для обучения нейросети

Эталонные ТС необходимы для обучения нейросети. Для специалиста, решившего применить нейросеть для решения какой-либо производственной задачи встает вопрос: какие ТС из их текущей череды выбрать в качестве эталонных? По аналогии с [2] перечислим основные положения, которые необходимы соблюдать при их выборе.

1. Технологические данные для обучения должны быть представительными (репрезентативными) как в совокупности, так и каждое в отдельности. Мнение программистов “garbage in, garbage out” (“мусор на входе – мусор на выходе”) нигде не справедливо в такой степени, как в нейросетевом моделировании.
2. Будущее не похоже на прошлое. Данные, собранные за прошлый период, могут не действовать в будущем. Это важно при определении размера “временного окна” и частоты обновления технологической информации.
3. Данные должны быть типовыми для рассматриваемой ТС. Нейросеть не может правильно решать задачи распознавания для резко отличающихся ТС, данные которых не входили в диапазон обучающего множества.
4. Набор данных должен быть сбалансирован. Необходимо стремиться к тому, чтобы информация для различных ТС в обучающей выборке была представлена равномерно, без выбросов.

В производственных условиях перечисленные требования практически реализуются в правильном выборе и обработке целевой функции, применяемой, например, при решении задачи оптимального управления. В этом случае ТС, соответствующая минимуму материальных, энергетических и информационных затрат выбирается в качестве эталона обучения. Кроме того, вид целевой функции для выбора эталонов должен отвечать следующим требованиям:

1. *Согласованность*. Целевая функция должна строиться на известных связях между входными и выходными параметрами, приведенных к одной координате объекта и моменту времени.
2. *Однозначность*. Одна целевая функция должна отражать изменение только одного критерия и иметь четкий физический смысл.
3. *Экстремальность* (вогнутость). У целевой функции должна быть ярко выраженная экстремальная область, распознаваемая экспертом.
4. *Ориентированность* на конкретный критерий, определяющий экономическую эффективность ТС.
5. *Соответствие*. Характер целевой функции и количественные характеристики ТС должны обеспечивать успешную оптимизацию технологического процесса.

6. *Управляемость.* В качестве аргументов должны фигурировать технологические параметры, поддающиеся управлению с помощью нейросети.

Для удовлетворения перечисленных требований целевую функцию  $F_{ц}$  располагают на графике в координатах X-Y (например, производительность – расход топлива), задавая последовательный ряд текущих ТС с условными номерами N1,... N12, как это изображено на рис.1.6. Далее фиксируют точку оптимума с координатами  $X_{опт} Y_{опт}$  и выбирают  $ТС_{опт}$  с N6 как наиболее подходящую, по мнению эксперта, в данном случае к оптимальным условиям.

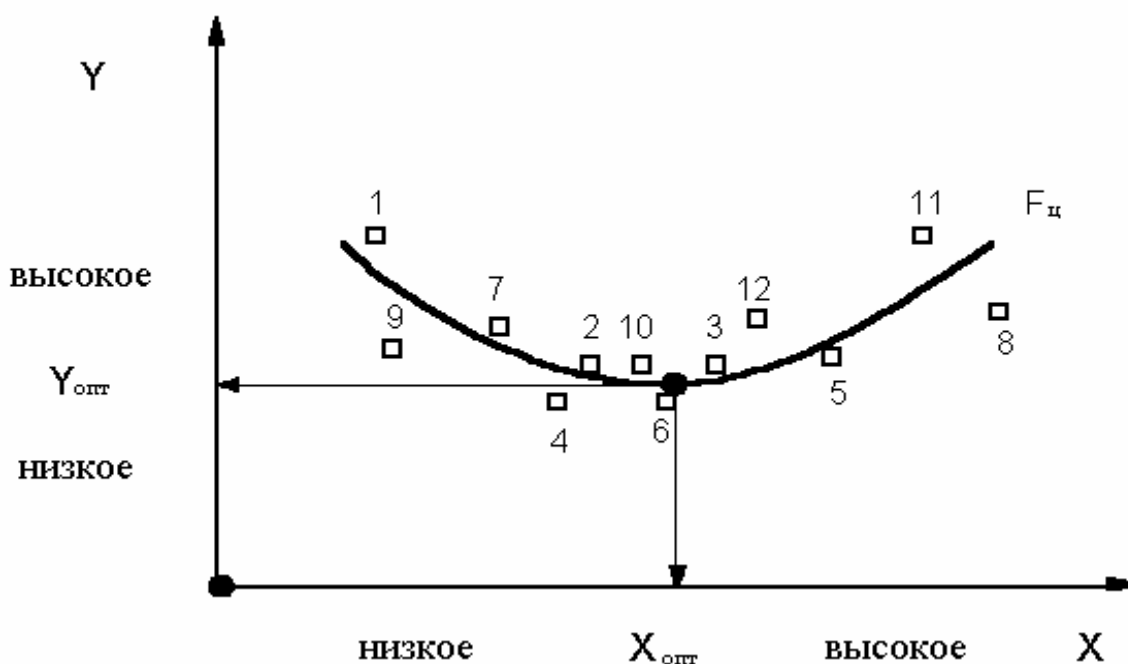


Рис. 1.6. Выбор оптимальной ТС в качестве эталона для обучения нейросети

В реальности часто приходится наблюдать большой разброс местоположений текущих ТС на графике относительно кривой целевой функции  $F_{ц}$ . Фактически определение положения  $ТС_{опт}$  также представляет собой задачу распознавания объекта, каковым является  $ТС_{опт}$ , на фоне изображения траектории технологического процесса с производственными шумами. Трудности решения такой задачи были отмечены выше, поэтому в данном случае, при выборе  $ТС_{опт}$  в качестве эталона для обучения еще несозданной нейросети часто прибегают к производственному опыту и инженерной интуиции специалистов. Так опытный производственник может

уверенно выбрать не только  $T_{C_{\text{опт}}}$ , но и указать пределы изменения  $X, Y$ , соответствующие их оптимальному, низкому и высокому значениям.

Построение кривой  $F_{ц}$  в условиях производственного шума необходимо дополнять корреляционной обработкой технологической информации. При выборе эталонов следует руководствоваться величиной коэффициента корреляции  $r$  для  $F_{ц}$ , значения которого должны быть не ниже граничных значений, приведенных в табл. 1.1.

Таблица 1.1

Значения граничных коэффициентов корреляции в зависимости  
от количества ТС на графике  $F_{ц}$

Количество ТС	3	4	5	6	7	8	9	10	11	12
$r$	0,998	0,995	0,990	0,980	0,950	0,707	0,665	0,632	0,602	0,576

Здесь предусмотрено, что наименьшее количество точек, по которым может быть построен график  $F_{ц}$  равняется 3. В то же время рассмотрение большего количества, чем 12 (числа, кратного количеству недель, месяцев в году) ТС нецелесообразно из-за ограничений на кратковременную память технолога-эксперта.

Если требуется несколько эталонов, (например, для диагностики дефектов продукции) их выбирают в зависимости от сочетания технологических факторов, от которых зависят эти дефекты, пользуясь значениями их ФП:

$$\text{ФП} = \lambda (\text{НЗК, ПНЖ, ОПТ, ПВШ, ВСК}), \quad (1.8)$$

здесь  $\lambda$  – квантификатор лингвистической переменной;

НЗК, ПНЖ,  
ОПТ, ПВШ,  
ВСК

– лингвистические переменные “низкий”,  
“пониженный”, “оптимальный”, “повышенный”  
и “высокий” соответственно.

Результаты определения эталонов сводят в обобщающую таблицу 1.2.

## Значения технологических факторов для эталонных ТС

Дефекты	Д 0	Д 1	Д 2	...	Д N
N нейронов	Н 0	Н 1	Н 2	...	Н N
Фактор 1	ОПТ	НЗК	ВСК	...	ПНЖ
Фактор 2	ОПТ	ПВШ	ПНЖ	...	ПВШ
...	...	...	...	...	...
Фактор N	ОПТ	ПНЖ	НЗК		НЗК

В таблице предусматривается бездефектная (Д0) ТС, когда все технологические факторы равны своим оптимальным значениям.

Количество факторов зависит от объема базы знаний в системе автоматизированного контроля технологического процесса, а количество различаемых лингвистических переменных и дефектов продукции определяется опытом и степенью компетентности специалистов. Таким образом, уже на стадии определения эталонов в обучение нейросети закладывается коллективный опыт ведения производства обслуживающим персоналом.

Общий алгоритм действий специалиста для определения необходимых эталонов обучения нейросети аналогичен алгоритму обработки экспертных оценок и приведен на рис. 1.7.

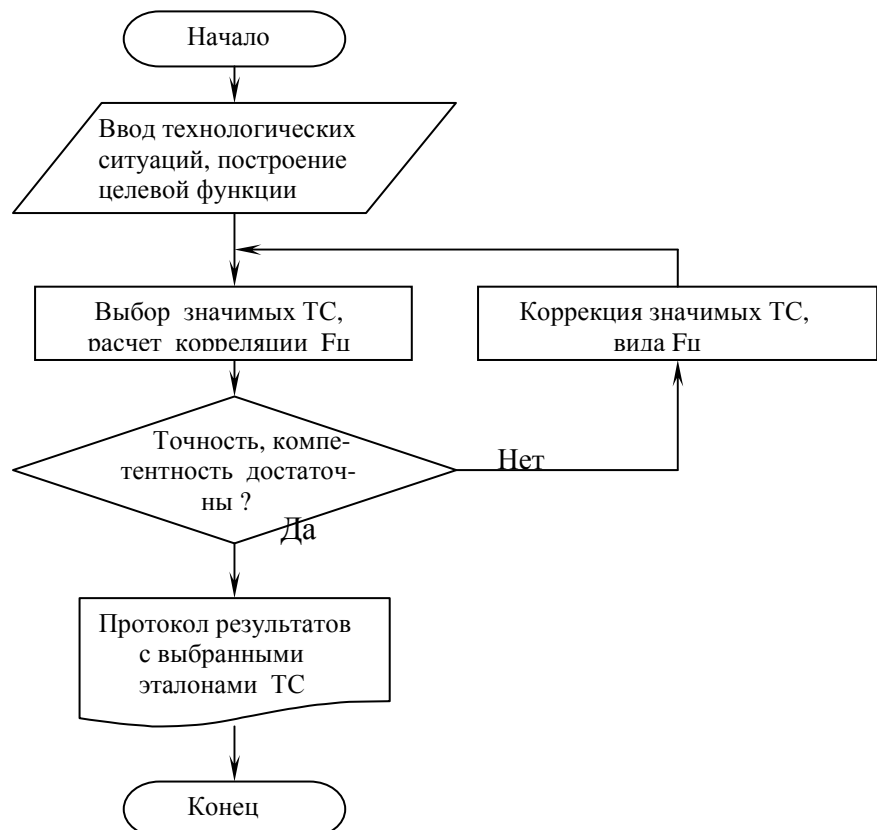


Рис. 1.7. Алгоритм выбора эталонов для обучения нейросети



## 1.7. Факторный анализ и получение новых знаний с помощью нейросетей

Как отмечалось ранее, внутренняя структура нейросети представляется для пользователя в виде “черного ящика”. Однако бывает целесообразно “заглянуть внутрь этого ящика”, например, чтобы выяснить наличие и вид новых взаимосвязей между входными параметрами и элементами обученной нейросети. Для этого необходимо воспользоваться методами факторного и регрессионного анализа.

При проведении анализа, в случае отсутствия в нейросетевом пакете опции внутренней активации, для простой однослойной сети нейросети или входных нейронов с ассоциаторами (рис.1.2) применяют тестовое множество входных сигналов. Например, чтобы определить вес  $w_i$  в каналах RGB, тестовое множество задают в виде таблицы-матрицы комбинаций входных нормированных сигналов.

Таблица 1.3  
Матрица входных сигналов для расчета весов внутренних связей нейросети

Канал \ N комбинации	R	G	B
1	1	0	0
2	0	1	0
3	0	0	1

Подавая на вход нейросети последовательно комбинации входных сигналов, производят расчеты выходного сигнала  $Y$ . Результаты представляют в виде гистограммы весов внутренних связей (рис.1.8).




Рис. 1.8. Гистограмма весов составного нейрона

В этом примере полученная гистограмма весов составного нейрона позволяет дать сравнительную оценку чувствительности к основным цветам человеческого глаза, адаптированного, как известно, к оптическим характеристикам земной атмосферы.

Обученную нейросеть можно представить как средство вычисления функции отклика в факторном или регрессионном анализе. В этом случае входные переменные нейросети будут представлять факторы, а их сочетание – определять входной вектор  $X$  в факторном пространстве по выражению транспонированной матрицы:

$$X = (x_1, \dots, x_n)^T. \quad (1.9)$$

Для оценки влияния на функцию отклика факторов её представляют в виде уравнения регрессии аддитивных составляющих  $f_i$  ( $i=1 \dots n$ ):

$$Y(X) = f_1(x_1) + f_2(x_2) + \dots + f_i(x_i) \dots + f_n(x_n). \quad (1.10)$$

Обычно в качестве первого приближения принимают линейный вид функций  $f_i$ . В этом случае функция отклика  $Y(X)$  определяется следующим образом:

$$Y(X) = \sum_{i=0}^n \beta_i x_i, \quad (1.11)$$

где  $\beta_i$  – коэффициенты регрессии;

$x_i$  – факторы (входные переменные).

Коэффициенты регрессии  $\beta_i$  характеризуют чувствительность функции отклика к соответствующим факторам и находятся, например, методом наименьших квадратов при корреляционной обработке данных.

Для целевой функции коэффициент множественной корреляции отражает размер относительной дисперсии точек модели  $\sigma_{\Delta}^2$  по сравнению с дисперсией значений отклика  $\sigma_y^2$ , так как  $\sigma_{\Delta}^2 / \sigma_y^2 = 1 - R_{yx}^2$ . Для оценки значимости каждого фактора следует использовать показатель в виде

$$(R_y^2 - R_{yx}^2), \% , \quad (1.12)$$

в котором  $R_y, R_{yx}$  – коэффициенты множественной корреляции, определяемые для случая наличия всех факторов и при отбрасывании рассматриваемого фактора, соответственно.

При выполнении факторного анализа с помощью нейросети выбирают базовую ТС, которая, как правило, входит в обучающее множество. Базовая ТС характеризуется входным вектором:

$$X^{\bar{b}} = (x_1^{\bar{b}}, \dots, x_n^{\bar{b}})^T, \quad (1.13)$$

где  $x_1^{\bar{b}}, \dots, x_n^{\bar{b}}$  – численные значения факторов входного вектора ТС, выбранной в качестве базовой.

Если определяют влияние факторов на прогнозируемые во времени значения функции отклика по формуле (1.10), то в качестве базовой ТС задают ТС, расположенную последней по ходу времени в заданном временном окне.

Далее выбирают необходимый или определяющий фактор (например,  $x_i$ ), значения которого линейно изменяют в пределах 10% от  $x_i^{\bar{b}}$ . Для установления характера функции  $f_i$  производят расчеты с помощью нейросети, варьируя значениями  $x_i$  и оставляя при этом постоянными на базовом уровне величины других факторов.

Принятый 10-процентный диапазон может не обеспечить линейный характер функции отклика, необходимый для расчета коэффициента  $\beta_i$ , поэтому результаты расчетов оформляют в виде графика зависимости  $Y(x_i)$ , по которому окончательно находят конкретные пределы линейного участка диапазона и соответствующее ему численное значение коэффициента регрессии.

Рассмотрим пример использования нейросети для факторного анализа доменного процесса, в котором определялось влияние содержания кислорода (O<sub>2</sub>) в комбинированном дутье на производительность (ПР) доменной печи (ДП) в конкретной ТС. На графике рис. 1.9 линейный характер функции отклика наблюдался в пределах изменения входного фактора O<sub>2</sub> от -8,54% до +2,41% относительно его базового значения. Этим пределам соответствовало изменение производительности ПР объекта от +4,087% до -2,634%.

Численное значение коэффициента регрессии составило:

$$\beta_{\text{ПР/O}_2} = (4,087 + 2,634) / (2,41 + 8,54) = 0,614 \text{ \%ПР / \%O.}$$

Часто особенностью функций отклика является её экстремальный характер (рис. 1.9.) с наличием восходящих и нисходящих участков, отражающих специфику каждой ТС на объекте. Например, если доменная печь работает на различных участках этих зависимостей, то при обычных методах управления доменной плавкой часто не реализуется переход на участок характеристики с оптимальными технико-экономическими показателями. Применение нейроробота позволяет учесть данные особенности и, тем самым, повысить эффективность управления.




Рис. 1.9. Экстремальное изменение производительности доменной печи в зависимости от содержания кислорода в комбинированном дутье

Полученные новые знания с помощью нейросетевого факторного анализа могут быть использованы технологами или мастерами доменной печи для разработки перспективных технологий.

## 1.8. Определение степени компетентности нейросетей и нейророботов

Нейросеть в процессе распознавания ТС имитирует действия специалиста или их коллектива. Последние в своих действиях могут допускать ошибки субъективного характера. Так как именно эксперты обучают нейросеть, то не исключено попадание такой ошибочной информации в эталоны обучения. Поэтому, наряду с обычной, возникает дополнительная потребность проверки надежности результатов, полученных с помощью нейросетей. Объективная проверка на точность субъективных решений связана с задачей обобщения и формализации характеристик экспертов на основе известных метрологических понятий.

*Физическая постановка* задачи по определению степени компетентности эксперта заключается в представлении его в виде своеобразной измерительной системы (рис. 1.10).

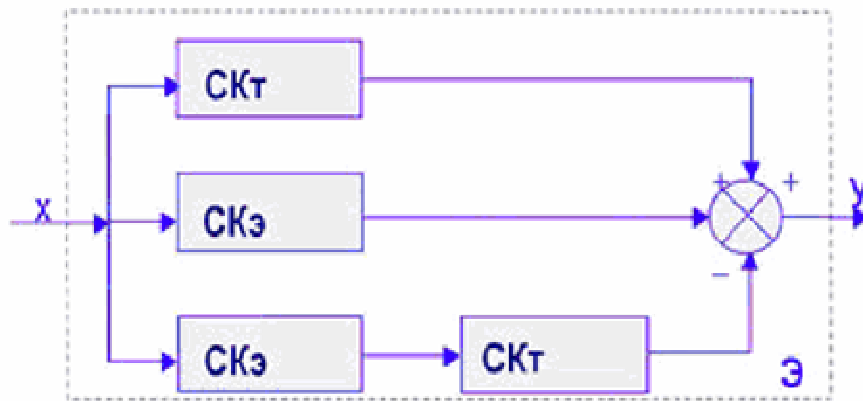


Рис. 1.10. Информационная схема экспертных измерений

Система состоит из функциональных звеньев с передаточными коэффициентами  $SK_T$  и  $SK_3$ , отражающими основные факторы, влияющие на степень компетентности эксперта и, в конечном итоге, определяющими погрешность его экспертных знаний и заключений (ЭЗЗ).

Исходная информация, представленная в виде вектора  $X$ , и поступает на вход системы и содержит две составляющие. Первая составляющая содержит ряд предварительных сведений. Эти сведения являются неизменными и включают основные характеристики технологического процесса, порядок воздействия на объект в нормальных и аварийных режимах согласно технологической инструкции. Качество знаний, полученных и усвоенных экспертом на основе внешней исходной информации, оценивают коэффициентом  $SK_T$ , характеризующим его степень компетентности в этом вопросе. Исходная информация, содержащаяся в технологических инструкциях, представлена в виде понятий, установленных коллективным опытом специалистов, равным образом компетентных в вопросах технологии и управления рассматриваемого объекта. В связи с этим распределение вероятностей ошибок ЭЗЗ на основе понятий в пространстве технологических признаков объект является равномерным. Равномерный закон распределения погрешностей учитывают при обработке информации в функциональных звеньях системы с коэффициентом  $SK_T$ . Такой подход предохраняет от ошибочных ЭЗЗ, свойственных индивидуальному знанию, и подчеркивает преимущество коллективного опыта.

Вторая составляющая вектора  $X$  представляет совокупность изменения технологических параметров, управлений и возмущений, которая создает у эксперта текущий образ ТС на объекте. Степень соответствия мысленного образа эксперта реальному положению объекта в пространстве оценивают с помощью коэффициента  $SK_3$ , характеризующего корреляционные способности специалиста, как идентификатора ТС. Так как образ определяется на основе субъективного индивидуального опыта, то распределение вероятностей погрешностей ЭЗЗ в пространстве

неравномерно. Для этого случая типичной является колоколообразная функция распределения ошибок, которая для случая “идеального” эксперта (не допускающего погрешностей) вырождается в кривую нормального распределения Гаусса. В этом случае в качестве наиболее вероятного образа ТС выступает состояние объекта с максимальным значением правдоподобия.

Таким образом, коэффициент  $СК_3$  характеризует производственный опыт эксперта и имеет функцию ошибок с нормальным законом распределения.

Процесс сопоставления исходной и текущей информации и процедура принятия решения центральной нервной системой человека хорошо изучены и формализованы в виде правил работы экспертных систем. На основе этих правил находится общая степень компетентности эксперта, проявляемая им при формировании ЭЗЗ в виде выходного вектора  $Y$ , с учетом изображенных на рис. 1.10 функциональных связей между составляющими  $СК_T$  и  $СК_3$ :

$$СК = (СК_T + СК_3) - СК_3 \cdot СК_T, \quad (1.14)$$

где  $СК_3$ ,  $СК_T$  – степени компетентности эксперта, найденные на основе корреляционного анализа практических данных и теоретического теста соответственно.

Численный расчет СК производится на основе среднего квадратичного отклонения (СКО) для принятых законов распределения составляющих погрешностей  $\delta_{СК_T}$ ,  $\delta_{СК_3}$  и вида корреляционной связи между ними. При этом принимают, что функция изменения уровня теоретических знаний эксперта не критична ко времени протекания производственного процесса, который по сравнению с этой функцией является существенно более динамичным. В реальности степень компетентности эксперта, обусловленная его теоретической подготовкой, не может изменяться во времени скачкообразно или резким образом, так как процесс накопления знаний требует длительного времени. Поэтому коэффициент корреляции между  $СК_T$  и  $СК_3$  практически равен нулю. Численные значения  $СК_i$  нормируют для диапазона 0..1, а их зависимости представляют в виде записи нечетких функций ФК следующим образом:

$$ФК = \langle ЛП_i, \Delta СК_i, ПБ, ЭО \rangle, \quad (1.15)$$

где  $ЛП_i$  – множество лингвистических переменных;  
 $\Delta СК_i$  – диапазон изменения степени компетентности;  
 $ПБ$  – алгоритм перебора лингвистических переменных;  
 $ЭО$  – алгоритм экспертного опроса.

Для определения общепринятых объективных метрологических характеристик таких как коэффициент корреляции ( $r$ ), относительная погрешность ( $\gamma$ ) применительно к нейросети, используют систему

уравнений, которые связывают эти характеристики с коэффициентами компетентности СК<sub>i</sub>:

$$\sigma_{СК} = \sqrt{2 \cdot (\sigma_{СКТ}^2 + \sigma_{СКЭ}^2)} \quad ; \quad (1.16)$$

$$r_3 = \sqrt{1/(1 + \sigma_{СК})} \quad ; \quad (1.17)$$

$$\gamma_3 = \sqrt{(1 - r_3^2)/4} \quad ; \quad (1.18)$$

$$N = \frac{1}{2} \cdot \gamma_3 \quad . \quad (1.19)$$

Здесь  $\sigma_{СК}$ ,  $\sigma_{СКТ}$ ,  $\sigma_{СКЭ}$  – СКО экспертных оценок и ЭЗЗ при нахождении коэффициентов СК, СК<sub>Т</sub>, СК<sub>Э</sub> соответственно;

$r_3$  – коэффициент корреляции, характеризующий корреляционные способности специалиста;

$\gamma_3$  – относительная погрешность ЭЗЗ;

$N$  – число градаций ТС, различаемых экспертом на графике целевой функции.

Используя практический опыт и профессиональные знания, технолог-эксперт устанавливает по результатам обработки на компьютере входной технологической информации возможное число градаций (информационных гранул), которое он в состоянии различить в каждой конкретной технологической ситуации согласно своей степени компетентности. Для системы (рис.1.10), на основе законов информационной теории измерений [4], взаимосвязь между числом различимых градаций и количеством информации выражается в виде уравнения:

$$N = 2^I, \quad (1.20)$$

где

$I$  – количество достоверной информации, бит.

Алгоритм определения степени компетентности нейросети принимается следующим. Задаются основные уровни качества результатов расчета и компьютерного моделирования, необходимые для решения конкретной технологической задачи. Далее находят значения погрешностей, которым должны удовлетворять эти расчеты. Для практического использования разработанного метода определения степени компетентности и контроля достоверности применяют таблицу 1.4.

Таблица 1.4

## Таблица погрешностей распознавания ТС с помощью нейросети и определения её степени компетентности

Относительная погрешность, %	Количество полезной информации, бит	Число градаций, различаемых технологом-экспертом, ед	Уровни вероятности результатов, доли ед	Проявленная степень компетентности	Достигнутый уровень качества результатов
> 35	0	1	0 - 0,707	недостаточная	требуется обучение или адаптация
35	1,0	2	0,707-0,891	достаточная	идентификация ТС
25	1,6	3	0,891-0,953	удовлетворительная	управление, стабилизация, прогноз
16	2,0	4	0,953-0,974	хорошая	оптимизация
12	2,6	6	0,974-0,988	очень хорошая	оптимизация с учётом риска
< 8	3,0	8	0,988-0,990	отличная	оптимизация с учётом риска

Например, если сравнение расчетных и экспериментальных данных, использованных при построении целевой функции  $F_{ц}$  и распознавании оптимальной ТС (см.рис. 1.6), показало отклонение ТС №6 от точки оптимума, равное 9,5 %, то согласно табл. 1.4 уровень качества распознавания способен обеспечить решение задачи оптимизации технологического процесса с риском. Этому показателю соответствует степень компетентности нейросети при её применении для принятия решения об оптимизации как “очень хорошая”, так как она способна различить не менее 6 градаций в технологической ситуации на объекте.

Определение степени компетентности нейросети, обученной экспертами, должно сопровождать все компьютерные расчеты, связанные с применением нейросетевой технологии.



## 1.9. Контрольные вопросы и задания

1. В чём заключается главная проблема задач распознавания и классификации?
2. Перечислите методы моделирования нейропроцессов при распознавании и классификации.
3. Назовите основные элементы модели составного нейрона.
4. Пользуясь функцией МОПРЕД электронной таблицы Excel, составьте программу для вычисления коэффициента множественной корреляции, характеризующего эффективность применения ассоциаторов составного нейрона.
5. Дайте определение функции принадлежности.
6. Составьте программу для определения ФП, описываемую кривой вероятности Гаусса, в электронной таблице Excel.
7. Что необходимо учитывать при формировании экспертных оценок для нейросети?
8. Перечислите основные требования для эталонов нейросети.
9. Что характеризует коэффициенты регрессии применительно к весам нейросети?
10. Для чего необходимо определять степень компетентности нейросети и нейророботов?
11. Перечислите основные уровни качества результатов, обеспечиваемые расчётами с помощью нейросетей.

## 2. Практический нейрокомпьютинг

В промышленном производстве технологический процесс, по сравнению с финансовым, маркетинговым и другими процессами, является основным, но в то же время наименее обеспеченным современным компьютерным сопровождением. Технологи не спешат внедрять “тяжелые” дорогостоящие системы типа планировщиков ресурсов и сверхбыстродействующие способы вычислений, так как аппаратные средства ПЭВМ и программное обеспечение быстро морально стареют, не окупая себя. Повышенным спросом на предприятиях пользуются открытые компактные интеллектуальные программы, не сложные в применении и обслуживании. Эффективность внедрения таких систем на локальном уровне достаточно высока. Практический нейрокомпьютинг вполне удовлетворяет таким требованиям технологов. Например, на заводах в Германии нейронные сети обеспечили 2%-е сокращение потребляемой электроэнергии и 5%-е увеличение производительности при производстве стали в электропечах [12].

Общая концепция применения нейросетевого обеспечения рассмотрена ниже на примере программного комплекса технолога предприятия. В нем ключевая задача повышения качества продукции решена с помощью нейросетевой системы диагностики дефектов изделий для условий Екатеринбургского завода керамических изделий, а типовая схема технологической диагностики с целью экономии энергоресурсов выполнена на нейросетях для такого энергонасыщенного и трудноконтролируемого объекта, как доменная печь.

Управление технологическими процессами с помощью нейросетей также перспективно, поэтому приведена разработка нейроробота для управления комбинированным дутьем в доменных печах с целью повышения эффективности использования топливных добавок и экономии дорогостоящего основного топлива – кокса. Программное обеспечение выполнено для условий ОАО “ММК” и ОАО “НТМК”, но может быть легко адаптировано для других заводов.

Для нестационарных условий работы технологического оборудования рассмотрено применение нейросети в управлении пусковым режимом объекта. Особенностью такой нейросети является её полностью детерминированный характер.

При разработках АСУ ТП широко применяется моделирование динамических свойств типовых звеньев систем. Такие примеры реализованы на нейронных сетях с обратными связями.

Уделено внимание применению нейросетей в торговых системах и в маркетинговом исследовании. Так, операции на рынке ценных бумаг целесообразно проводить с помощью нейроробота “УНИКОМПАРТНЕР”, а нейромаркетинг позволяет определить рыночную цену продукции, которая является оптимальной для производителя.

## 2.1. Применение нейросетей в программном комплексе специалиста – технолога

Концептуальная модель применения нейросетей в программном комплексе для технологических расчетов и проектирования заводов и предприятий представлена на рис. 2.1. Модель состоит из следующих основных модулей:

- 1 — модель технолога-эксперта;
- 2 — оценки качества применяемых технологических решений;
- 3 — модели предприятия;
- 4 — модели программного комплекса для технологических расчетов и проектирования;
- 5 — интерфейсы технолога для принятия решения;
- 6 — базы знаний, например, системы “Галактика”.

Модель основана на следующих информационных методах:

- компьютерное моделирование;
- линейное программирование;
- теория принятия решений;
- распознавание образов;
- нейронные сети.

Новые технологические решения реализуются следующим образом.

При поступлении информации о целесообразности перехода на новую технологическую ситуацию эксперт-технолог (1) задается необходимым уровнем качества принятия решения (2). Например, для оптимизации технологии необходимо достигнуть точности технологических расчетов и решений, характеризуемой относительной погрешностью не более 8 %. Далее определяются основные показатели (например, объем производства) с помощью модели (3). Эта информация является исходной для технологических расчетов и проектирования, осуществляемых в модуле (3) с использованием базы знаний системы “Галактика” (6). Программные модули “Галактики” [13] в данном случае наиболее близки по своей структуре и идеологическому построению к требованиям, предъявляемым к их совместному применению с нейросетями.

Результаты компьютерных расчетов и моделирования далее используются для решения задач выбора экспертом-технологом (1) оптимальной технологии или режима в модуле (5). Результаты выбора оцениваются экспертом, и принимается окончательное решение о возможности оптимизации технологии или принимаются альтернативные решения.

Концептуальная модель предусматривает применение нейросетей для фильтрации входной информации, определение степени компетентности

технолога – эксперта и его решений, диагностики и управления технологическим процессом, оценки рыночных рисков при изменении качества продукции и т.п. Рассмотрим далее конкретный пример использования нейросети для диагностики качества керамических изделий.

## **2.2. Диагностика дефектов производства облицовочной плитки с помощью компьютерной нейросети**

### **2.2.1. Постановка задачи**

Процесс производства керамики связан с большой вероятностью появления различного рода дефектов во время обжига, вследствие сложности этого технологического процесса. Чтобы контролировать появление дефектов, возникающих в результате отклонения технологических параметров от нормы, предлагается применить нейросеть, которая помогает “распознать” дефекты, путем оперативного слежения за процессом обжига. Тем самым, становится возможным избежать появления брака продукции, увеличить производительность и уменьшить себестоимость изделий. Результатом работы компьютерной программы является расчет вероятности дефектов и параметров качества диагностики: относительной погрешности, степени компетентности нейромоделей, моделирующей действия опытного технолога, и уровня качества диагностики.

### **2.2.2. Математическая формулировка задачи диагностики**

Общая задача математического моделирования в данном случае – это определение вида возможных дефектов облицовочной плитки. Вид дефектов – это подмножество таких вариантов, в которых может быть принято одно и то же диагностическое решение. Их разделяют на бездефектный вариант и варианты с наличием дефектов.

Для построения модели диагностики процесса используют теорию множеств, которая представляет модель в виде кортежа [14] :

$$\Delta = \langle T, X, Y, Z, F, L \rangle, \quad (2.1)$$

где  $T$  – множество моментов наблюдения во времени;

$X, Y$  – входные и выходные технологические параметры соответствующего множества;

$F$  – оператор переходов, который описывает изменение состояния процесса под действием внутренних и внешних возмущений;

$Z$  – множество состояний процесса;

$L$  – оператор выходов, описывающий механизм формирования выходного диагностического сигнала.

Кортеж (2.1) описывает состояние процесса однозначно, причем порядок следования элементов – это предмет договоренности опытных технологов.

В процессе диагностики выполняют задачу классификации на нейросетях  $\eta : Y \rightarrow E$ , (2.2)

где  $\eta$  – отображающая функция;

$Y$  – вектор выходных технологических параметров;

$E$  – классы множества выходных технологических параметров.

Задача классификации подразделяется на ряд этапов:

- 1) разбиение множества  $Y$  на ряд непересекающихся классов, и определение каждого параметра к одному из этих классов. Пример: характеристики температуры обжига и гранулометрический состав массы плитки;
- 2) построение модели процесса (множества  $E$ ), которое учитывает конкретные условия работы на производстве и требования к результатам диагностики;
- 3) выработка решения о принадлежности текущего состояния технологического процесса к одному из классов (видов) возможных дефектов:

$$y \in Y, \quad (2.3)$$

где  $y$  – характеристика (влажность, температура, химический состав и т.д.);

$$e \in E, \quad (2.4)$$

где  $e$  –дефект.

Для решения поставленной задачи классификации отвечают на следующие вопросы:

- 1) каковы признаки классов дефектов плитки?
- 2) сколько надо признаков в каждой конкретной технологической ситуации?
- 3) в каком порядке определяются совпадения признаков выходного сигнала вероятности дефектов и классов?

На основании этапов 1 и 2 строят алгоритм диагностики и модель процесса контроля. Алгоритм должен предусматривать:

- 1) нахождение общих свойств сигналов вероятности дефектов  $Y$ , определение в какой степени эквивалентности  $Q$  соотносятся эти сигналы:

$$Q = Y \times Y; \quad (2.5)$$

- 2) факторизацию

$$v : Y \rightarrow Y/Q, \quad (2.6)$$

где  $Q$  – количество классов  $Y$ ;

3) операцию классификации

$$\kappa: E \rightarrow Y/Q, \quad (2.7)$$

где  $\kappa$  – отображение классов состояний на классы контролируемых или выходных сигналов;

4) вычисление функции, отображающей классы состояний  $E$  на реальные области возможных технологических ситуаций на обжиговой линии

$$\psi: E \rightarrow S. \quad (2.8)$$

Далее представляют общую диаграмму диагностики в форме на рис. 2.2.




Рис. 2.2. Диаграмма диагностики технологического процесса производства облицовочной плитки

### 2.2.3. Алгоритм решения задачи диагностики

Далее рассматривают обнаружение и диагностику дефектов как задачу распознавания образов. Образ в данном случае – это расположение информации о дефектах по определенной форме [15]. Распознавание образов – это процесс установления вида или класса дефектов плитки на основе определенных признаков образа, поэтому метод распознавания представили как трехступенчатый процесс (рис. 2.3).

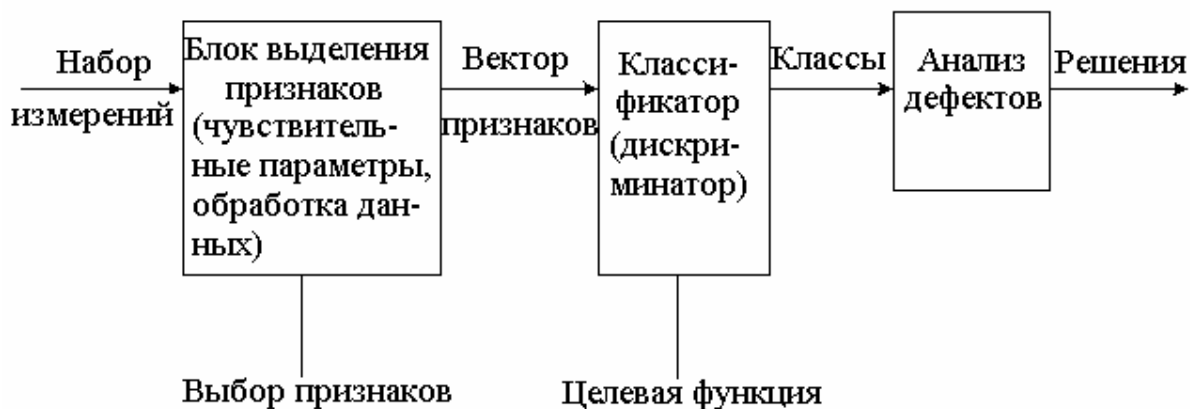


Рис. 2.3. Процедура распознавания образов методом выделения признаков и классификации

В начале выполняют соответствующие технологические измерения, результаты которых составляют пространство измерений. Измерения представляют в виде вектора  $\underline{X} = [X_1 X_2 \dots X_M]^T$ , в котором элементы  $X_1, X_2, \dots, X_M$  обозначают скалярные величины измеренных технологических величин.

На втором этапе по результатам измерений вычисляют и выделяют характерные признаки, объединяемые в вектор признаков, входящий в пространство признаков. Эти признаки определяют непосредственно из измерений путем удаления лишних компонентов из вектора  $\underline{X}$ . Вектор в пространстве признаков  $\underline{Y}$ , соответствующий вектору измерений  $\underline{X}$ , рассчитывают как  $\underline{Y} = [Y_1 Y_2 \dots Y_N]^T$  с  $N < M$ . Признаки матрицы измерений находят путем проведения преобразований над ней и выбора системы преобразованных компонентов матрицы, которые «наилучшим образом» характеризуют диагностическую систему.

Окончательно выбранные признаки представляют в векторной форме.

Далее применяют решающее правило по отношению к вектору пространства признаков для классификации векторов признаков на один или более классов, после чего проводят анализ дефектов плитки.

*Использование кластеризации*, а в данном случае для нее была эмулирована на компьютере нейронная сеть, позволяет идентифицировать области в изучаемом пространстве дефектов, и связать их с образами различных классов. Кластеры определяются с использованием доверительных границ, соответствующих вероятности ошибок распознавания дефектов, как показано на рис. 2.4.

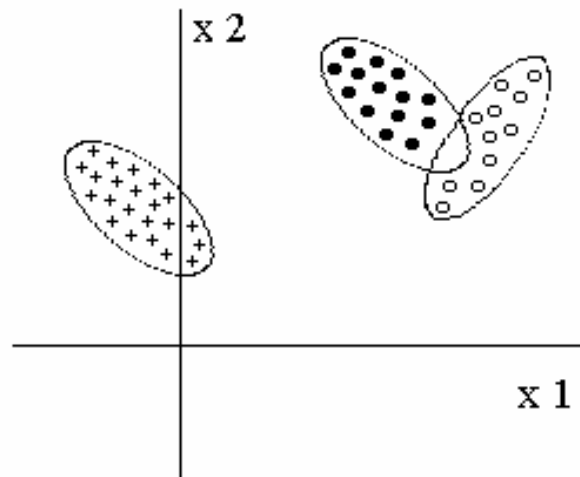


Рис. 2.4. Результаты измерений двух технологических переменных:  
 o – нормальная работа (нейрон Д0);  
 • – работа с дефектом 1 (нейрон Д1);  
 + – работа с дефектом 2 (нейрон Д2);  
 — — — контуры доверительных областей (для доверительной вероятности 0,90);  
 x1 – контролируемый параметр - температура обжига плитки;  
 x2 – контролируемый параметр - степень неравномерности температурного поля для трех различных результатов работы.

На рис. 2.4. кластеры выделены доверительными границами.

#### 2.2.4. Синтез нейросети для решения задачи диагностики

Синтез нейронной сети для распознавания производят в следующем порядке:

1. Составляют таблицу дефектов плитки и технологических причин их возникновения [16].
2. Составляют таблицу для обучения нейросети.
3. Синтезируют нейросеть, например, с помощью пакета ExNP.

Результат представляют в виде проекта сети, который приведен на рис. 2.5.

Созданная нейросеть состоит из 6 нейронов – идентификаторов 5 разновидностей дефектов и одного нейрона – идентификатора нормального состояния процесса. Число входных факторов было принято равным девяти и определялось контролируемыми параметрами, отклонения которых от нормы вызывали дефекты. Кроме того, каждый параметр задается тремя лингвистическими переменными типа “высокий-низкий-оптимальный”.



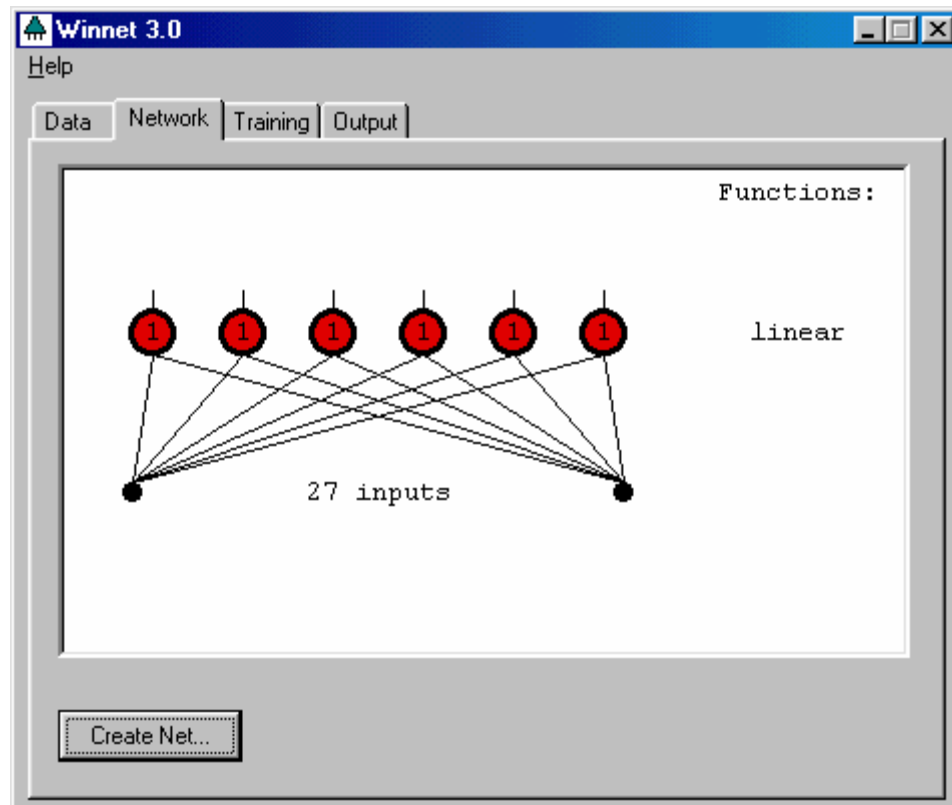


Рис. 2.5. Проект нейросети в пакете ExNP

Лингвистические переменные задаются функциями принадлежности (ФП). Эти функции осуществляют перевод текущих технологических параметров в их вероятностную форму.

### 2.2.5. Процесс диагностики нейросетевым методом

Процесс диагностики в виде схемы представлен на рис. 2.6.

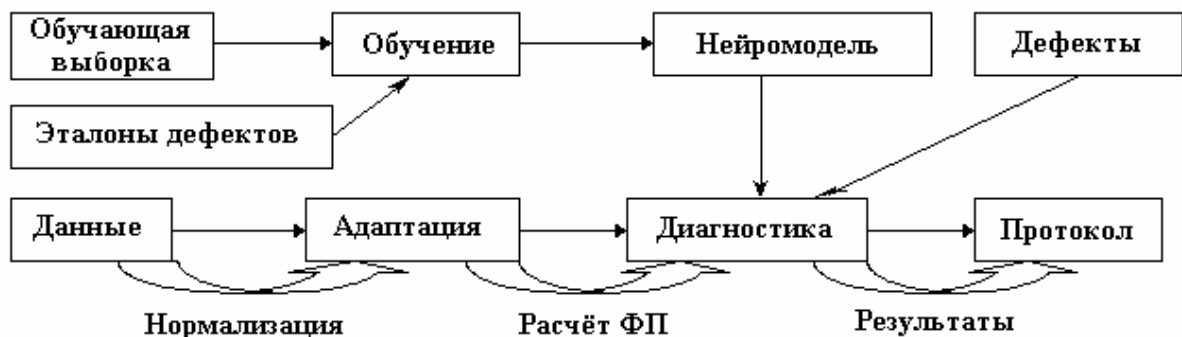


Рис. 2.6. Информационная схема процесса диагностики

Расчет степени вероятности дефектов производят в указанной модели по формуле:

$$ВРД_N = \frac{\Delta N}{\sum_{N=1}^N \Delta N}, \quad (2.9)$$

где ВРД<sub>N</sub> – вероятность появления N-го дефекта, доли ед.

$\Delta N$  – абсолютное значение выходного сигнала нейрона, предсказывающего вероятность N-го дефекта.

N – количество выходных нейронов (количество дефектов + 1).

$$\sum_{N=1}^N ВРД_N = 1. \quad (2.10)$$

Исходная информация о процессе для диагностики представлена в табл. 2.2.1.

Таблица 2.2.1

Исходная технологическая информация

1. Коэфф. неравн. в зоне С1						
Значение для диагностики	Граничные значения ФП					
	малое		оптимальное		большое	
	мин	макс	мин	макс	мин	макс
1,77	1,55	2,00	1,55	2,00	1,55	2,00
2. Коэфф. неравн. в зоне С2						
Значение для диагностики	Граничные значения ФП					
	малое		оптимальное		большое	
	мин	макс	мин	макс	мин	макс
1,77	1,55	2,00	1,55	2,00	1,55	2,00
3. Коэфф. неравн. в зоне Н1						
Значение для диагностики	Граничные значения ФП					
	малое		оптимальное		большое	
	мин	макс	мин	макс	мин	макс
4,32	4,14	4,50	4,14	4,50	4,14	4,50

Продолжение таблицы 2.2.1

4. Коэфф. неравн. в зоне Н2						
Значение для диагностики	Граничные значения ФП					
	низкий		оптимальный		высокий	
	мин	макс	мин	макс	мин	макс
8,29	7,57	9,00	7,57	9,00	7,57	9,00
5. Скорость нагрева в зоне Н2						
Значение для диагностики	Граничные значения ФП					
	низкая		оптимальная		высокая	
	мин	макс	мин	макс	мин	макс
46,07	30	80	30	80	30	80
6. Темпер. обжига в зоне В2						
Значение для диагностики	Граничные значения ФП					
	низкая		оптимальная		высокая	
	мин	макс	мин	макс	мин	макс
1080	1075	1085	1075	1085	1075	1085
7. Скорость обжига в зоне В2						
Значение для диагностики	Граничные значения ФП					
	низкая		оптимальная		высокая	
	мин	макс	мин	макс	мин	макс
49,47	30	65	30	65	30	65
8. Коэфф. неравн. в зоне В2						
Значение для диагностики	Граничные значения ФП					
	низкое		оптимальное		высокое	
	мин	макс	мин	макс	мин	макс
4,32	3,09	7,00	3,09	7,00	3,09	7,00
9. Скорость охлаждения в зоне О2						
Значение для диагностики	Граничные значения ФП					
	низкое		оптимальное		высокое	
	мин	макс	мин	макс	мин	макс
112,03	80	150	80	150	80	150

*Диагностируемые параметры:*

1. Коэфф.неравн.в зоне С1	1,77 %
2. Коэфф.неравн.в зоне С2	1,77 %
3. Коэфф.неравн.в зоне Н1	4,32 %
4. Коэфф.неравн.в зоне Н2	8,29 %
5. Скорость нагрева в зоне Н2	46,07 град./мин
6. Темпер. обжига в зоне В2	1080 град.С
7. Скорость обжига в зоне В2	49,47 град./мин
8. Коэфф.неравн. в зоне В2	4,32 %
9. Скорость охлаждения в зоне О2	112,03 град./мин

Результаты диагностики получают путем расчета вероятностей дефектов по данным выходных сигналов нейронов (см. зависимость 2.7.2.).

Компьютерная реализация программы диагностики позволила все результаты оформить в виде сводного протокола, пример которого для данного случая представлен ниже.

### Протокол диагностики

*Диагностика процесса тепловой обработки облицовочной плитки*

*с использованием нейронной сети*

Дата анализа:	07.06.03
№ варианта:	1
Исполнитель:	Кириллова М.В.
Группа:	СМ-575

### Продолжение протокола диагностики

*Результаты диагностики (вероятности дефектов):*

1.Наколы на глазури	0,059
2.Сборка глазури	0,071
3.Треск обжига	0,045
4.Треск охлаждения	0,027
5.Трещины сушки	0,000
Без дефектов	0,798

*Параметры качества диагностики:*

Относит. погрешность диагностики:	35%
Степень компетентности нейромодели:	Достаточная
Уровень качества диагностики:	Идентификация технологической ситуации

*Рекомендации нейромодели:*

Процесс в норме

Заключение эксперта-технолога:

Рекомендации нейромодели подтверждаю.

Подпись исполнителя:

Эффективность работы нейросети можно продемонстрировать путем построения примера рабочей поверхности двух нейронов Д2, Д0 – идентификаторов дефекта 2 (“сборка глазури”) и бездефектного варианта соответственно. Пример такой поверхности в координатах вероятностей дефектов, отклонений температуры обжига и степени неравномерности температур в плитке от нормы приведён на рис. 2.7.6.




Рис. 2.7.6. Совместные поверхности диагностики нейронов Д2 и Д0

Здесь наглядно показано, что при отсутствии отклонений технологических параметров от нормы, вероятность бездефектной работы максимальна. При возникновении отклонений повышается и постепенно

достигает также своего максимума вероятность возникновения дефекта (здесь “сборка глазури”), что приводит к максимальному значению выходного параметра нейрона Д2.

В реальности диагностические поверхности имеют более сложный вид, чем представленный пример. Однако их изображение в гиперпространстве 9 координат в настоящее время даже в компьютерных технологиях пока не представляется возможным.

### **2.3. Диагностика распределения материалов и газов в доменной печи**

В настоящее время, ввиду тенденции снижения интенсивности доменной плавки и роста экономичности процесса, роль распределения материалов и газов в доменной печи существенно возросла [17]. Однако оперативный контроль этого распределения практически остается недостаточным из-за отсутствия необходимой измерительной аппаратуры. Указанный недостаток можно компенсировать путем применения нейронных моделей [18]. Нейронная модель, имитируя работу мозга специалиста путем генерации мысленных образов, активизирует память, профессиональный опыт мастера печи и позволяет, тем самым, более полно охватить всю совокупность факторов и явлений доменного процесса при его диагностике. В итоге возрастает степень компетентности решений по управлению доменной плавкой в условиях недостатка оперативной информации.

#### **2.3.1. Физическая постановка и математическая формулировка задачи диагностики доменного процесса**

Физическая постановка задачи диагностики заключается в следующем. Доменный процесс рассматривается как непрерывный во времени ряд технологических ситуаций (ТС). Каждая ТС описывается набором понятий (например, периферийный, центральный, оптимальный поток и т.п.), которые использует мастер, технолог печи для качественной оценки и управления распределением материалов и газов по радиусу шахты и горна. Требуется произвести классификацию ТС по эталонам возможных радиальных распределений потоков и определить на основе имеющейся технологической информации, к какому эталону относится текущий вариант ТС.

Таким образом, в отличие от известных математических формулировок задачи о движении материалов и газов в шахтных печах, в данной работе предусмотрено, что моделируется не сам доменный процесс, а действия «идеального» мастера или технолога печи, как лица принимающего решения (ЛПР) по результатам диагностики.

В этом случае математическая формулировка задачи о диагностике распределения материалов и газов в доменной печи включает в себя описание модели ТС в виде упорядоченного множества, содержащего как наиболее влияющие на распределение, так и зависящие от него параметры:

$$ТС = \langle КЭД, СИГ, ПРК, Т \rangle \quad (2.3.1)$$

Компоненты множества обозначены следующим образом:

КЭД – кинетическая энергия комбинированного дутья;

СИГ – степень использования газа;

ПРК – приведенный расход кокса;

Т – время.

Таким образом, ТС представлена вектором в пространстве состояний доменной печи. В фиксированный момент времени  $T = I$ ,  $ТС_i$  описывается этим вектором с проекциями на оси координат,  $ПРК_i$ ,  $КЭД_i$ ,  $СИГ_i$ , представляя собой текущий образ ТС.

Классификация ТС составляется на основе типовой технологической инструкции по доменному производству путем выделения из общего множества векторов состояний определенных эталонов, характеризующих возможные варианты качественного распределения материалов и газов. Число эталонов, равное девяти, определяется путем расчета разноименных сочетаний трех видов распределений (центральное (Ц), оптимальное (О), периферийное (П)) для двух фаз: газа и материала. Образы этих эталонов, рекомендуемые для восприятия ЛПР, приведены на рис. 2.3.1. Следовательно, решение задачи диагностики заключается в определении искомого вектора  $ТС_i$  и оценке принадлежности этого вектора к одному из принятых эталонов.

Методика определения вектора  $ТС_i$  предусматривает разделение его проекций на множества, которые математически описывают понятия, привычно используемые ЛПР для текущей характеристики технологических факторов. Набор этих понятий соответствует количеству переменных состояний, безизбыточному и достаточному для однозначной идентификации всех эталонов при решении задачи в ее трехмерной постановке:

$$\begin{aligned} КЭД &= \lambda_1 (\text{ВСК, ОПТ, НЗК}); \\ СИГ &= \lambda_2 (\text{ВСК, ПВШ, ПНЖ, НЗК}); \\ ПРК &= \lambda_2 (\text{ВСК, ПВШ, ПНЖ, НЗК}), \end{aligned} \quad (2.3.2)$$

где ВСК, ПВШ,  
ПНЖ, НЗК,

ОПТ – лингвистические переменные «высокий»,  
«повышенный», «пониженный», «низкий»,  
«оптимальный» соответственно;

= – равно по определению;

$\lambda_1, \lambda_2$  – операция квантификации для трех и четырех множеств соответственно.

### 2.3.2. Определение параметров нейронной модели

Вид функций (2.3.2) определяется экспертным методом. В данном случае использовали результаты компьютерного опроса мастеров и технологов – экспертов, которые указали для выбранной доменной печи наиболее вероятное, по их мнению, распределение численных значений КЭД, СИГ и ПРК внутри каждого из диапазонов, т.е. ВСК, ОПТ, НЗК и т.д. Таким образом, учитывались нечеткий характер информации, коллективный опыт работы персонала и конкретные особенности технологии доменной плавки. В результате построили нормированные амплитудные характеристики моделирующих нейронов-дискретизаторов, которые определяли их степень возбуждения (СВ), т.е. выходной сигнал в зависимости от силы входного сигнала, например, компонентов КЭД, ПРК (рис. 2.3.2, 2.3.3).




Рис. 2.3.2. Амплитудная характеристика для компонентов КЭД






Рис. 2.3.3. Амплитудная характеристика для компонентов ПРК

Для диагностики ТС была разработана нейронная модель, топология которой представлена на рис. 2.3.4. Модель состояла из трех слоев нейронов. Первый слой вычислял нормированные сигналы, пропорциональные компонентам КЭД, СИГ и ПРК на основе текущей информации, поступающей с доменной печи. Второй слой нейронов выполнял функции дискретизации при моделировании лингвистических переменных. Третий, выходной слой нейронов, идентифицировал принадлежность ТС к одному из эталонов.

Преобразование информации моделью рассмотрено ниже на примере нейронов-идентификаторов. Каждый нейрон представлял собой сумматор, на вход которого подавались через связи сигналы, пропорциональные СВ нейронов-дискретизаторов. СВ нейрона усиливалась, если на его вход поступал положительный сигнал (+) и, наоборот, уменьшалась, если входной сигнал был отрицательным (-). В соответствии с общим числом лингвистических переменных, равным в модели 11, на вход каждого нейрона-идентификатора подходило 3 положительных и 8 отрицательных связей. Набор положительных связей определялся видом эталона и был установлен при классификации ТС (см. рис. 2.3.1).

Текущая СВ нейронов рассчитывалась по известным правилам суммирования воздействий при имитации процесса диагностики в экспертных системах [19]:

– для положительных связей:

$$СВ(+)=СВ_1(+)+СВ_2(+)+СВ_1(+)\cdot СВ_2(+); \quad (2.3.3)$$

– для отрицательных связей:

$$СВ(-)=СВ_1(-)+СВ_2(-)+СВ_1(-)\cdot СВ_2(-); \quad (2.3.4)$$

– для противоположных по воздействию связей:

$$СВ=\frac{СВ(+)+СВ(-)}{1-\min\{|СВ(+)|,|СВ(-)|\}} \quad (2.3.5)$$

Идентификация текущей ТС производилась нейронной моделью по максимальному значению СВ, которую приобретал только один из девяти выходных нейронов-идентификаторов.

Проверку адекватности нейронной модели произвели путем сопоставления результатов идентификации распределения материалов и газов с экспериментальными данными, полученными методом горизонтального зондирования на двух горизонтах во время исследования доменных печей. Для этого использовали информацию о радиальном распределении рудной нагрузки и скоростей газов на доменной печи объемом 1370м<sup>3</sup>. Радиальные измерения проводились во время отработки технологии плавки при содержании в рудной части шихты: 100% неофлюсованных окатышей; 30% окатышей и 70% агломерата; 100% офлюсованного агломерата. Кроме этого, использовались замеры на доменной печи объемом 2013м<sup>3</sup>, при ее работе с различным количеством и диаметром воздушных фурм. По результатам более 300 диагностических решений установили, что степень правильной идентификации ТС нейронной моделью превышала 75...80% от общего числа ТС, предъявленных для диагностики. Это показало возможность диагностики распределения материалов и газов в доменной печи с помощью нейронной модели с точностью, достаточной для практического использования.

Адаптация модели заключалась в коррекции амплитудных характеристик нейронов в зависимости от условий доменной плавки и профессионального опыта персонала. Для этого использовали усредненные за недельный период технологические параметры, а затем по ним уточняли диапазоны изменения компонентов КЭД, СИГ, ПРК и вид амплитудных характеристик нейронов-дискретизаторов, при которых экспертами однозначно выбирался нужный эталон распределения.

### 2.3.3. Применение разработанной нейромодели доменной печи

Разработанный метод был применен для диагностики распределения материалов и газов в доменной печи объемом 1513м<sup>3</sup> ОАО “НТМК”.

Рассмотрены 12 недельных периодов ее работы в январе – марте 1995 г. Для иллюстрации выбраны характерные периоды 15.01.95–21.01.95, 15.02.95–21.02.95, 07.03.95–13.03.95, в которых имели место центральное, оптимальное и периферийное распределение материалов в шахте и горне доменной печи.

Основные технологические показатели и результаты диагностики доменной плавки в этих периодах приведены в табл. 2.3.1. Например, в опытный период 07.03.95–13.03.95, при работе печи с приведенным расходом кокса, равным 471 кг./т.чуг., были получены СВ нейронов, численно равные 0,99 для положительной связи и соответственно 0,48, 0,43 и 0,19 – для отрицательных связей (см. рис. 2.3.4). Согласно формулам (2.3.3) – (2.3.5), общая СВ нейрона-идентификатора от компонента ПРК для переменной ПНЖ составила 0,954. Такой же порядок численных значений СВ имел место и для других компонентов. Этот пример свидетельствовал о достаточной надежности диагностики с помощью нейронной модели, которая уверенно идентифицировала фактические распределения материалов и газов в рассмотренные опытные периоды и отнесла эти распределения к 3, 6 и 7 эталонам ( см. табл. 2.3.1).

Кроме рассмотренного примера нейронная диагностика была использована для оптимизации расходов природного газа и кислорода в комбинированном дутье группы доменных печей и прогнозирования снижения расхода кокса в условиях ОАО “ММК”. С ее помощью еженедельно проводилась идентификация преобладающего характера газового потока (Ц, О, П) на печах в целом и фиксировалось текущее значение КЭД, приведенное по аналогии с расходом кокса, к одинаковым условиям работы печей (рис. 2.3.5).

При отклонениях газораспределения от оптимального, производились расчеты и выдавались рекомендации на коррекцию расходов природного газа и кислорода, изменения числа и диаметра работающих воздушных фурм. Например, на доменных печах, объемом 2013 м<sup>3</sup>, увеличили число воздушных фурм с 20 до 25 шт. и последовательно уменьшили их диаметр – сначала со 180 до 160, а затем и до 150 мм. Одновременно произвели коррекцию режима загрузки, увеличив долю подачи типа КРРК.

С целью прогноза построили изменение усредненного значения КЭД во времени (см. рис. 2.3.5). Усредненное значение находили методом цифровой обработки, что позволило определить целесообразность стратегического снижения общего уровня интенсивности комбинированного дутья на доменных печах АО “ММК” на 25%.

Таблица 2.3.1

Основные технологические параметры доменной печи  
№ 3 АО НТМК при диагностике вида распределения  
материала и газа в доменной печи

№ п/п	Наименование показателей	Период		
		15.01– 21.01.95	15.02– 21.02.95	07.03– 13.03.95
1	Производительность, т чугу./сут.	2518,0	2695,0	2409,0
2	Расход кокса, кг/т чугу.	472,0	467,0	492,0
3	Расход агломерата, кг/т чугу.	786,0	851,0	773,0
4	Расход окатышей, кг/т чугу.	919,0	849,0	992,0
5	Расход дутья, м <sup>3</sup> /мин	2871,0	2722,0	2680,0
6	Давление горячего дутья, атм.	2,36	2,34	2,19
7	Температура дутья, град. С	1142,0	1146,0	1124,0
8	Расход природного газа, м <sup>3</sup> /т чугу.	110,0	101,0	97,0
9	Содержание кислорода в дутье, %	22,70	22,75	22,10
10	Содержание кремния в чугуне, %	0,190	0,160	0,360
11	Содержание СО в колошн. газе, %	21,30	22,10	20,40
12	Содержание СО <sub>2</sub> в колошн. газе, %	19,0	17,2	17,5
13	Содержание железа в шихте, %	57,52	57,44	57,53
14	КЭД, Кдж/час	268000,0 (НЗК)	329300,0 (ОПТ)	390000,0 (ВСК)
15	ПРК, кг/т чугу.	475,0 (ПНЖ)	451,0 (НЗК)	471,0 (ПНЖ)
16	СИГ, доли	0,4715 (ПВШ)	0,4377 (ПНЖ)	0,4617 (ПВШ)
	Выход на эталоны (рис. 2.3.1)	3	6	7




Рис. 2.3.5. Изменение во времени значения оптимальной кинетической энергии (КЭД) для доменных печей АО “ММК”: Ц, О, П – центральное, оптимальное, периферийное газораспределение в горне соответственно;

- ..... оптимальное значение КЭД;
- текущее значение КЭД;
- усреднённое значение КЭД методом цифровой фильтрации.

Практическим результатом такого снижения явилась реализация резервов экономии удельного расхода кокса порядка 20 кг/т чугуна.

Возможность повышения точности нейронной диагностики обусловлено увеличением размерности рассмотренной модели (2.3.1) и числа эталонов. Однако практическая реализация этой возможности в настоящее время ограничена количеством амплитудных характеристик нейронов, которое может уверенно описать технологический персонал доменной печи без повышения своей квалификации.

Таким образом, методика диагностирования распределения материалов и газов в доменной печи с помощью нейронной модели позволяет на основе текущей типовой технологической информации надежно определять вид этого распределения и дать рекомендации по его совершенствованию. Это повышает эффективность управления пара-метрами комбинированного дутья и режимами загрузки, что в итоге приводит к экономии кокса.

## **2.4. Нейроробот “ПАРТНЕР МАСТЕРА” для управления комбинированным дутьём доменных печей**

Современные информационные технологии могут превратить персональный компьютер в достаточно эффективное устройство – нейроробот для управления параметрами комбинированного дутья доменных печей. Разработанное для этой цели программное обеспечение способно решать две основные задачи по управлению доменным процессом: 1 – снижение удельного расхода кокса и повышение производительности; 2 – повышение эффективности использования природного газа или топливных добавок к дутью.

Нейроробот предназначен для регулярного использования технологами, мастерами доменных печей и может быть реализован на любом компьютере, класса Р-II и выше, имеющемся в их распоряжении. Данный нейроробот также легко встраивается в существующие АСУ ТП доменными печами, превращая их в гибридные системы управления.

### **2.4.1. Особенности нейроробота “Партнер мастера”**

В программном обеспечении нейроробота применены нейронные сети, обучающиеся при их использовании. При управлении моделируется не сам доменный процесс, а действия опытных мастеров, технологов по определению управляющих воздействий и выработки рекомендаций. Обученная на основе коллективного опыта персонала нейросеть совместно с аппаратными принадлежностями представляет собой инструментальное средство для управления доменной печью с помощью компьютера - нейроробот. Для достижения необходимой эффективности программное обеспечение дополнено методом расчета функции отклика (целевой функции управления) и методом определения степени компетентности нейроробота, связанной с обычными метрологическими понятиями, применяемыми для оценки погрешностей управления. Последнее существенно повышает надежность получаемых результатов и доверие доменщиков к рекомендациям нейроробота.

### **2.4.2. Основные принципы управления с помощью нейроробота**

На рис. 2.4.1. представлена схема НСУ на базе нейроконтроллера, реализующего заданный закон управления. На его входной слой нейронов поступают сигналы внешнего задания  $u_r(k)$  и обратной связи по выходу

объекта  $y(k)$  на  $k$ -м шаге, а также задержанный сигнал обратной связи  $y(k-1)$  на предыдущем шаге. Выходной нейрон нейроконтроллера формирует сигнал управления на  $k$ -м шаге  $u(k)$ . В качестве нейроконтроллера можно использовать многослойный перцептрон (МСП) с тангенциальными активационными функциями нейронов скрытого слоя.

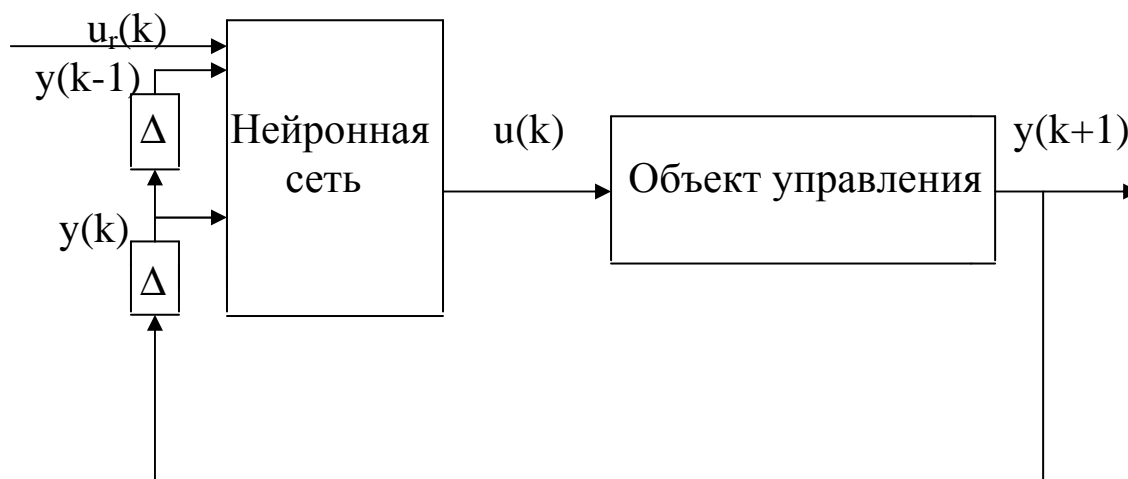


Рис. 2.4.1. Схема дискретной НСУ

Настройка параметров нейроконтроллера проводится с помощью основанного на генетическом алгоритме метода стимулированного контролируемого обучения. При этом используется тренировочный набор сигналов, содержащий возмущающую функцию Хевисайда. Практическая реализация метода изложена ниже.

### 2.4.3. Обучение нейроробота “ПАРТНЕР МАСТЕРА”

На основе типовой текущей информации формировалась обучающая выборка данных, в которую технологом-экспертом включались наиболее представительные и характерные технологические ситуации (ТС) на доменной печи. Количественные (число ТС) и временные (длительность “временного окна”) размеры выборки определялись в зависимости от числа факторов (производительность печи, удельный расход кокса, температура дутья, содержание Si в чугуне и т.п.) и конечной цели применения программы – управление в режиме реального времени, прогноз, анализ опытных плавов и т.д. Так, в примере, приведенном ниже, размер временного окна выбран равным 12 неделям, с недельным интервалом усреднения данных, а расчет рекомендаций по оптимальным значениям расходов природного газа и кислорода в дутье производился с целью включения их в месячную технологическую карту работы доменной печи. Количество

одновременно анализируемых факторов принималось равным 24, что было вполне достаточно в данном примере для адекватного представления технологическим персоналом общей картины протекания доменного процесса.

На основе этой информации и заданных, согласно цели управления, функций отклика осуществлялось деление факторов на входные или выходные и производился *синтез нейромоделей*. Пример типовой нейросетевой структуры приведен на рис. 2.4.2.

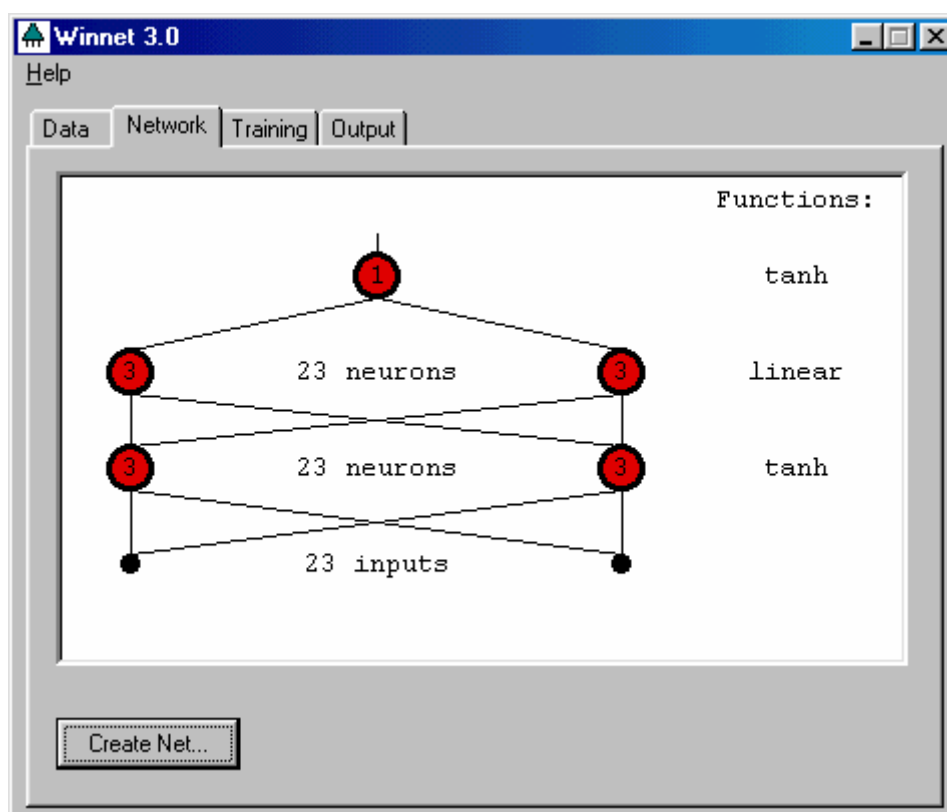


Рис. 2.4.2. Нейросеть для расчета удельного расхода кокса и производительности доменной печи в зависимости от значений технологических факторов.


В этом примере количество входных факторов (переменных) было равным 23. Информация о них подавалась на входы также 23 нейронов (нелинейных сумматоров). В качестве выходных факторов (на рис. 2 – нейрон третьего, выходного слоя) принимались удельный расход кокса (РК) и производительность печи (ПР) в первом и втором проектах нейросетей соответственно.

*Обучение* нейросетей состояло в определении связей между нейронами. Для этого осуществлялась подача на их вход реальных величин переменных



факторов выбранной ТС, на выход – эталонных значений удельного расхода кокса и производительности для этой же ТС. Процесс обучения являлся автоматизированной процедурой и происходил для заданной заранее пользователем ошибки обучения. Созданная и обученная нейросеть записывалась в качестве рабочего проекта в файл специального формата.

Способность нейромодели адекватно реагировать на новую, не включенную в обучающую выборку ТС на доменной печи, оценивалась путем определения её *степени компетентности*. Для этого применялась контрольная выборка производственных данных новой ТС и специальная методика расчета информационных погрешностей, созданная в УГТУ-УПИ. Выходные данные, отражающие достигнутые возможности, представлялись компьютерной программой по форме:

Технолог. факторы		
Отн.погр. контр.варианта, %	0,24	12,55
Отн.погрешность нейроробота, %		12,55
Степень компетентности нейроробота в оценке ТС:		Хорошая
Уровень качества получаемых результатов:		Оптимизация
Рекомендации по использованию нейроробота:		Возможно использование нейроробота для цели управления ДП

#### 2.4.4. Адаптация нейроробота “ПАРТНЕР МАСТЕРА”

*Адаптация* нейроробота заключалась в вводе в обучающую выборку текущей информации, коррекции обучения и в установлении реальных ограничений на диапазон изменения управляющих факторов, таких как содержание природного газа и кислорода в комбинированном дутье, что показано в табл. 2.4.1.

## Базовые и экспертные пределы управляющих воздействий

Значение технологического параметра	Содержание ПГ в дутье , м <sup>3</sup> /т чугу.	Содержание O <sub>2</sub> в дутье , доли
	10	12
	ПГ <sub>дуть</sub>	O <sub>2</sub> <sub>дуть</sub>
Базовое	99,0000	0,2460
Мин. реком. -10%	89,1000	0,2214
Макс. реком.+10%	108,9000	0,2706
Мин. эксперта	90,0000	0,2250
Макс. эксперта	110,0000	0,2800

### 2.4.5. Результаты применения нейробота на доменных печах

Процесс определения управляющих воздействий осуществлялся в процедуре *Анализа* и контролировался пользователем в режиме диалога с нейроботом. Для этого компьютерная программа содержала обзорные графики влияния управляющих факторов на удельный расход кокса и производительность доменной печи, окна рекомендаций нейробота, подтверждения или ввода пользователем скорректированных значений. Примеры работы программы даны для условий работы доменной печи ОАО “НТМК” и представлены на рис. 2.4.3-2.4.6.




Рис. 2.4.3. Обзорный график для оценки возможности снижения удельного расхода кокса




Рис. 2.4.4. Обзорный график для определения сопутствующего изменения производительности печи в случае коррекции расхода природного газа

**Выбор параметров 1**

1. Выберите РК

РК, %
-3,995

2. Выберите ПГ, соответствующий ранее выбранному РК

РК, %	ПГ, %
-3,995	11,11

3. Выберите ПР(ПГ)

ПГ, %	ПР(ПГ), %
11,11	-0,770

4. Выберите компенсирующее изменение ПР(O<sub>2</sub>)

ПР(O <sub>2</sub> ), %
0,871

5. Выберите O<sub>2</sub>дут.

ПР(O <sub>2</sub> ), %	O <sub>2</sub> , %
0,871	-1,24

ОК

Рис. 2.4.5. Диалоговое окно выбора и коррекции управляющих воздействий нейроробота на комбинированное дутье доменной печи




Рис. 2.4.6. Обзорный график для решения технологической задачи повышения эффективности использования природного газа в доменной печи

Обзорные графики также являются примером получения новых знаний о доменном процессе методом факторного анализа. Полученные характеристики весьма существенно отличаются от принятых технологами представлений зависимостей РК, ПР от содержания ПГ и O<sub>2</sub> в дутье. Их особенностью является экстремальный характер с наличием восходящих и нисходящих участков, отражающих специфику каждой ТС на доменной печи. Если доменная печь работает на различных участках этих зависимостей, то при обычных методах управления доменной плавкой часто не реализуется переход на участок характеристики с оптимальными технико-экономическими показателями. Нейроробот позволяет учесть данные особенности и, тем самым, повысить эффективность управления.

На заключительном этапе работы нейроробота формировался протокол с результатами и вычисленными управляющими воздействиями. Предусматривалась запись управляющих воздействий как в ячейки электронной таблицы, так и в выходной файл данных для управления.

#### 2.4.6. Состав и реализация программного обеспечения нейроробота

Программное обеспечение выполнено и распространяется в виде файлов электронной таблицы Excel, как известно, имеющейся в составе стандартного комплекта Microsoft Office и файлов с проектами нейросетей. Общий объем информации в файлах не превышает 1 Мб. Для генерации и обучения нейроробота также используется стандартная и свободно распространяемая надстройка для работы с нейросетями в Excel – пакет ExNP

(1,2 Мб.). Программа составлена по блочному принципу и состоит из 13 основных блоков-листов.

*Лист Ввод.* Служит для стыковки программы с базой данных и знаний предприятия. Преобразование форматов осуществляется средствами Excel. В качестве примера данных на листе приведено содержимое текстового файла MS DOS, преобразованного в нужный формат. Информация является реальной и соответствует технологическим данным работы доменной печи ОАО “НТМК”.

*Лист Данные.* Содержит пример формата данных, необходимого для расчета с помощью нейросетевого пакета ExNP. Этот формат и обозначения идентификаторов технологических факторов используются на всех других листах программы.

*Лист Обучение.* Здесь формируется обучающая выборка ТС доменной печи.

*Лист Контроль.* Осуществляется ввод средствами Excel информации о ТС, предназначенной для определения степени компетентности нейромодели.

*Лист Компет.* Выводятся результаты контрольной проверки нейроробота и рекомендации о возможностях его использования.

*Лист Базовая ТС.* Предназначен для ввода информации о базовой ТС, выбранной пользователем.

*Листы Ввод РК, Вывод РК, Ввод ПР, Вывод ПР .* Предназначены для ввода информации в нейросетевые пакеты, производства необходимых расчетов и вывода результатов в ячейки электронной таблицы для функций отклика удельного расхода кокса и производительности доменной печи соответственно.

*Листы Анализ1 и Анализ2.* Предназначены для решения технологических задач по снижению удельного расхода кокса и повышению эффективности использования природного газа в доменной печи соответственно.

*Лист Протокол.* Содержит выходную форму результатов работы компьютерной программы для распечатки на принтере или дальнейшем использовании в АСУ ТП.

Результаты применения нейроробота показали целесообразность его применения в гибридных системах управления комбинированным дутьем

доменной печи. Программное обеспечение передано ОАО “УРАЛГИПРОМЕЗ” для использования в проектах систем автоматизации доменных печей и ОАО “НТМК”, ОАО “СЕВЕРСТАЛЬ” для реализации на действующих печах.

Разработанная методика синтеза НСУ является универсальной для всех типов объектов управления. Нелинейность нейронных сетей и их уникальные аппроксимационные свойства теоретически позволяют решать в рамках нейроуправления задачи любого уровня сложности. При этом структура нейроконтроллера и время его обучения не увеличиваются с возрастанием сложности объекта управления. Для большинства практических задач управления верхнюю границу сложности нейроконтроллера можно оценить как 20 – 40 нейронов входного слоя и 50 – 100 нейронов скрытого слоя. А это значит, что для синтеза соответствующей НСУ вполне достаточно персонального компьютера и 10 – 100 часов машинного времени.

## 2.5. Нейроуправление пусковыми режимами технологических объектов большой единичной мощности

Вывод на заданный рабочий режим интеллектуально сложных и энергонасыщенных технологических объектов после их ремонта или кратковременной остановки является ответственной операцией. В этот период управление агрегатом осуществляется непосредственно опытным обслуживающим персоналом. Выбирая управляющие воздействия, ЛПР стремится сократить время пускового периода, сопровождающегося, как правило, перерасходом энергоресурсов и потерей производительности. Одновременно ЛПР предотвращает возможные аварийные ситуации и поломки оборудования. Применение в режиме пуска нейросетевого управления позволяет оптимизировать траекторию выхода объекта на технологический режим путем одновременного учета опыта ЛПР, его эмоционального состояния и особенностей технического состояния оборудования, что недоступно обычным системам и регуляторам “жесткого” программного действия.

### 2.5.1. Нейронная модель для пуска технологического оборудования.

*Задача модели:* обеспечить оптимальную траекторию выхода на заданный технологический режим.




Рис. 2.5.1. Структура сети (аналог робота "Спиди")  
Виды межнейронных связей:  $\longrightarrow$  (+) – усиливающая связь;

—●(-) – тормозящая связь.

На рис. 2.5.1. представлена структура семантической сети, где введены следующие обозначения нейронов:

- (1). – ”Нагрузка”;
- (2). – ”Интенсивность отказов” (вибраций);
- (3). – ”Приказ”;
- (4). – ”Опасность”;
- (5). – ”Страх поломки”;
- (6). – ”Уверенность”;
- (7). – Уменьшить нагрузку;
- (8). – Увеличить нагрузку.

Модель содержит 3 слоя нейронов: I слой – информационный, воспроизводит сигналы ”Нагрузка”, ”Интенсивность отказов”, ”Приказ”; II слой – эмоционального состояния; III слой – управляющий. Возбуждение сенсоров (1), (2) находится в прямой зависимости от состояния среды или положения объекта. Зависимость между синапсами ”Нагрузка”, ”Интенсивность отказов” принята следующей (рис. 2.5.2.).

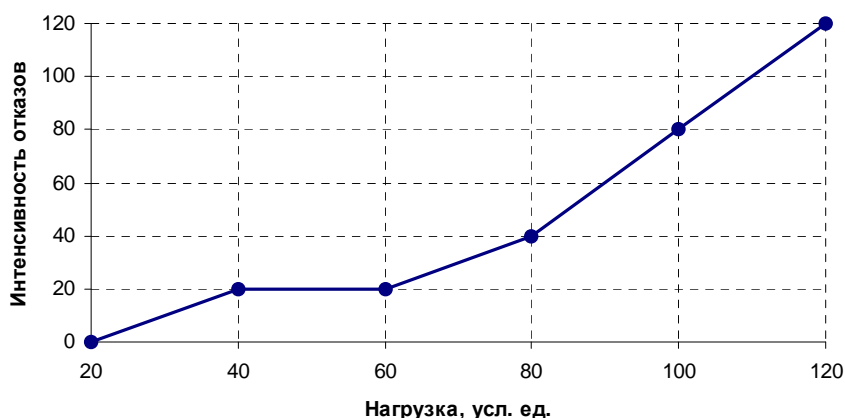


Рис. 2.5.2. Пример зависимости функции интенсивности отказов от нагрузки

Было установлено, что в реальности оператор почти всегда даёт постоянную команду на пуск с помощью ручки управления ,нейрон (3), по силе, равной 30 усл. ед.

### 2.5.2. Характеристика i–модели (нейрона)

При малых воздействиях нейрон не возбуждается, а затем возбудимость на выходе увеличивается пропорционально величине входного воздействия. Однако при достаточно больших входных воздействиях уровень возбуждения меняется мало. Таким образом свойства нейрона отражены



характеристикой типа логарифмического усилителя с зоной нечувствительности:

$$\Pi^{\tau+1} = K_H \ln(E_a^\tau - \theta),$$

где  $K_H$  – коэффициент возбудимости нейрона;

$E_a^\tau$  – входной сигнал;

$\theta$  – порог чувствительности;

$\Pi$  – реакция нейрона.

### Особенности работы.

Определение возбужденности  $i$ -модели нейрона возможно только в том случае, если в предыдущий момент модель не была возбуждена и если на вход приходят только усиливающие воздействия. Однако реально чаще всего бывает наоборот, т.е. существует собственное возбуждение и тормозные воздействия. Например, характеристика затухания нейрона выглядит так

$$\Pi^{\tau+1} = \Pi^\tau \cdot \alpha,$$

где  $\alpha$  – коэффициент затухания.

Пусть в момент времени  $\tau$   $i$ -модель была возбуждена до величины  $\Pi_1$ , если бы входных воздействий не было, то в момент времени  $\tau+1$  возбужденность этой  $i$ -модели составила бы  $\Pi^{\tau+1} = \Pi_1 \cdot \alpha$ . В "пересчёте на вход" это соответствует входному воздействию  $E_1$  в момент времени  $\tau$  (рис. 2.5.3.). Пусть в этот же момент  $\tau$  на вход  $i$ -модели поступило активное воздействие  $E_a$ . Сумма  $E_1 + E_a$  за вычетом порога  $\theta$  и определяет возбужденность модели в момент  $\tau+1$ . Из логарифмической характеристики следует, что

$$E_1 = \exp(\Pi_1 \cdot \alpha / K_H) ,$$

т.е. при отсутствии тормозных воздействий

$$\Pi^{\tau+1} = K_H \cdot \ln[E_a^\tau + \exp(\Pi^\tau \cdot \alpha / K_H) - \theta].$$



Рис. 2.5.3. Вид характеристики возбуждения  $i$ -модели

Теперь необходимо учесть процесс торможения. Логичнее всего отражать тормозное воздействие изменением возбудимости  $i$ -модели, т.е. коэффициентом наклона её характеристики возбуждения, поэтому принимается

$$K^\tau = K_H - m \cdot E_T^\tau,$$

где  $K_H$  – начальное значение коэффициента возбудимости;

$E_T^\tau$  – тормозное входное воздействие;

$m$  – масштабный коэффициент.

Окончательное определение возбудимости необходимо производить по кривой  $K^\tau$ .

$$\Pi^{\tau+1} = (K_H - m \cdot E_T^\tau) \cdot \ln \left( E_a^\tau + \exp \left( \frac{\Pi^\tau \cdot \alpha}{K_H} \right) - \theta \right).$$

В упрощённом варианте (линейная модель нейрона) основные уравнения будут такими:

$$\left. \begin{aligned} \Pi^{\tau+1} &= \Pi^\tau \cdot \alpha \\ K^\tau &= K_H - m \cdot E_T^\tau \\ \Pi^{\tau+1} &= (E_a^\tau - \theta) \cdot K_H \end{aligned} \right\} .$$

Величины активных и тормозных воздействий на  $i$ -модель подсчитываются следующим образом:

$$E_a^\tau = \sum_j^n \Pi_j^\tau \cdot r_{ij}, \quad E_T^\tau = \sum_j^n \Pi_j^\tau \cdot \tilde{r}_{ij},$$

где  $r_{ij}$ ,  $\tilde{r}_{ij}$  – активные и тормозные связи соответственно.

Возбуждённость  $i$ -модели должна быть одного и того же порядка. Это необходимо для нормального переключения системы усиления-торможения (СУТ). Средний уровень  $\Pi_i = 100$  ед.

Примем коэффициент затухания для моделей (4) – (6)  $\alpha = 0,5$ . Тем самым, мы задаём ”кратковременную память”, достаточную для влияния в течении двух-трёх последних моментов времени. Что же касается рецепторных (1) – (3) и эффекторных (7) – (8), то здесь ”забывание” нецелесо-образно и для них  $\alpha = 1,0$ .

Следует дать определение коэффициента возбудимости  $K_H$ . Так как размер сети мал, то не возникает причин для разнообразия значения  $K_H$ . Входное возбуждение по активным связям в среднем для одной  $i$ -модели 200 ед. Цифра получена так: при средней возбуждённости 100 ед. и связях  $r_{ij} = 0,5$  средняя величина

$$E_a^\tau = \sum_j^n \Pi_j^\tau \cdot r_{ij} = 200,$$

из расчёта, что на  $i$ -модель приходит (3) – (5) связей.

Примем, что  $\Pi_i \cdot \alpha / K_H$  примерно на порядок меньше  $E_a^\tau$ , и, следовательно, новая информация (возбуждающая) имеет большее влияние,

чем память. Поскольку  $\Pi_i \cdot \alpha = 100 \cdot 0,5 = 50$  ед., величина  $K_H$  должна быть близкой к единице.

Примем  $K_H = 1,5$  для  $i$ -модели (4) – (8) и  $K_H = 1$  для рецепторных моделей (1), (2), (3). Пусть коэффициент пропорциональности обеспечивает превышение  $K_H$  относительно  $m \cdot E_T$  примерно на порядок. Зададим значение  $m = 0,01$ . В нашем случае на  $i$ -модель приходит не более одной тормозной связи, следовательно, в среднем  $E_T = 100 \cdot 0,5 = 50$  и  $m \cdot E_T = 0,5$ , т.е. такая величина  $m$  нас устраивает. Отметим, что если выражение  $K_H - m \cdot E_T^r$  принимает значение  $K_H - m \cdot E_T^r \leq \theta$ , то считается, что  $i$ -модель полностью заторможена и её возбуждённость равна нулю.

### 2.5.3. Расчёт связей между нейронами

Такие допущения, как ”величина А должна быть на порядок больше величины В”, носят эвристический характер и могут уточняться в процессе работы с моделью. Что касается порогов, то  $\theta = 0$  – для чёткости. Однако введение порогов может существенно упростить настройку сети. Успешность функционирования модели в значительной степени от величины проходимости между  $i$ -моделями ( $r$ -связи). Связи удобно задать в виде матрицы (рис. 2.5.4).

а

i \ j	1	2	3	4	5	6
4	–	1	–	–	–	–
5	–	–	–	0,3	–	–
6	1	–	–	–	0,3	–
7	–	–	–	0,3	0,5	0,3
8	–	–	1	–	0,3	0,5

б

i \ j	1	2	3	4	5	6
4	–	1	–	–	–	–
5	–	–	–	0,5	–	0,3
6	1	–	–	–	0,3	–
7	–	–	–	0,5	0,7	0,1
8	–	–	–	–	0,1	0,7

Рис. 2.5.4. Матрица  $r$ -связей в качестве ”начального варианта”:  
 а – Матрица –  $M_1$ ; б – Матрица –  $M_2$

Номера столбцов в матрице равны номерам  $i$ -модели, от которых отходят связи  $j$ , номера строк равны номерам  $i$ -моделей, к которым подходят связи  $i$ . Цифры на пересечении  $i$ -строки и  $j$ -столбца соответствуют проходимости связей между  $i$ -моделями. Связи разделены на три группы: сильные, средние, слабые,  $\sim$  – тормозные связи.

*Сильные связи* : от  $i$ -модели "Приказ" к  $i$ -модели "Увеличить нагрузку";  
от  $i$ -модели "Нагрузка" к  $i$ -модели "Уверенность";  
от  $i$ -модели "Интенсивность отказов" к  $i$ -модели "Опасность". Таким образом  $r_{83} = r_{42} = r_{61} = 1$ .

*Средние связи*: от  $i$ -модели (5) и (6) к  $i$ -моделям (7) и (8),  
 $r_{86} = r_{75} = 0,5$ .

*Слабые связи*: все остальные, их проходимости  $\approx 0,3$ .

Установлением определённых связей, заданием параметров характеристик и величин проходимости можно задать "характер" модели. Легко можно увидеть, что повысив величину связи от  $i$ -модели "Опасность" – к  $i$ -модели "Страх", мы делаем модель более "пугливой". Аналогичного эффекта можно добиться, повысив коэффициент возбудимости  $i$ -модели "Страх" или "Опасность".

#### 2.5.4. Задание исходного состояния сети

В принципе можно задать любое распределение возбуждений на  $i$ -моделях, исходя из среднего уровня  $P_{cp} = 100$ . Этим мы задали бы "временную память" о её прошлом опыте. Однако поскольку такая "память" была бы очень произвольна, а в нашей модели элементов "произвольности" достаточно, поэтому пусть она начинает жизнь с "нуля". Постоянная память зафиксирована в связях модели, "временная" – в величинах возбуждаемости. Модель работает по тактам  $\tau, \tau+1, \tau+2, \dots$ . Совокупности операций по определению возбудимости  $i$ -модели на следующем шаге представляют пересчёт.

Если матрицы коэффициентов постоянны, то задаются только правила СУТ (системы усиления-торможения).

*Пример.*

СУТ делят на одноуровневые и многоуровневые. Рассмотрим одноуровневую СУТ: система из всех нейронов выбирает наиболее возбужденную  $i$ -модель (по амплитуде выходного сигнала) и дополнительно увеличивает сигнал на 30 единиц. В следующий момент (такт времени) для модели изменение в коэффициенте затухания ( $\alpha' = \alpha - 0,3$ ) и коэффициенте возбудимости ( $K'_H = K_H - 0,3$ ) составит

соответственно. Уменьшение  $\alpha$  и  $K_H$  у выбранной  $i$ -модели происходит каждый такт до момента, когда СУТ не выберет другую модель. Пусть  $i$ -модель (А) в момент  $\tau_1$  имела возбужденность  $\Pi=150$  ( $\alpha = 0,8$ ;  $K_H = 1,5$ ) и была выбрана СУТ, то её параметры должны изменяться следующим образом. В момент времени  $\tau_1$   $\Pi = 150 + 30 = 180$  ( $\alpha = 0,8$ ;  $K_H = 1,5$ ); в момент  $\tau_2$   $\Pi = x_1$  (зависит от связей А с другими нейронами),  $\alpha = 0,5$ ,  $K_H = 1,2$ ; в момент  $\tau_3$   $\Pi = x_2$ ,  $\alpha = 0,2$ ,  $K_H = 0,9$  и т.д. Это происходит до тех пор, пока СУТ не выберет модель (В). Начиная с этого момента  $\alpha$  и  $K_H$   $i$ -модели (А) принимают начальное значение, т.е.  $\alpha = 0,8$ ,  $K_H = 1,5$ . Если в какой-то момент оказывается, что  $\alpha < 0$  или  $K_H < 0$ , то принимается  $\alpha = 0$ ,  $K_H = 0$ . В том случае, если СУТ выбирает более одной  $i$ -модели (при равной их возбужденности), дополнительное возбуждение 30 единиц распределяется на эти  $i$ -модели равномерно.

При выборе СУТ одной из  $i$ -моделей действий (7) или (8) изменяются параметры среды. Это означает изменение возбужденности "рецепторных" моделей (1) и (2) в соответствии с новым положением. При одновременном выборе СУТ обоих действий – решение не принимается. После выполнения одного действия считается, что возбуждение обоих действий снижается до нуля согласно схеме алгоритма рис. 2.5.5.

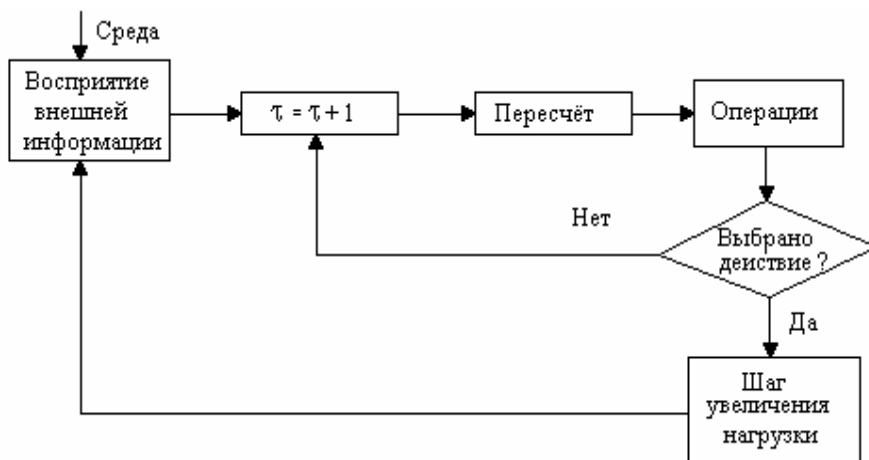


Рис. 2.5.5. Блок-схема алгоритма СУТ

### 2.5.5. Расчет оптимального переходного процесса

*Пример пересчёта.*

Исходные данные: модель (1)–(3):  $\alpha = 1$ ,  $K_H = 1$ ;  
 (4)–(6):  $\alpha = 0,5$ ,  $K_H = 1,5$ ;

$$(7), (8): \alpha = 1, K_H = 1,5;$$

$$\theta = 0, P_D = 30 \text{ ед.}$$

После выбора СУТ  $i$  – модели, её параметры изменяются по закону:

$$\alpha' = \alpha - 0,3,$$

$$K'_H = K_H - 0,3.$$

Используется матрица постоянных связей  $M_1$  (рис. 2.5.4).

*Расчет начальных тактов.*

*Такт 1.*  $P_3 = 30$ , рассчитываем воздействие нейрона (3) на нейрон (8):

$$P_8 = (1,5 - 0,01 \cdot 0) \cdot \left( \frac{0 \cdot 0,5}{1,5} + 30 - 0 \right) = 45.$$

Остальные нейроны возбуждения не получают.  $P_3 = 30$  (const)  $\Rightarrow P_8 = 45$ . СУТ выбирает нейрон (8) и сеть выбирает шаг "увеличить нагрузку". Нагрузка возрастает до 20 ед. Однако она незначительна и интенсивность отказов равна нулю.

*Такт 2.*  $P_1 = 20, P_3 = 30$  (приказ остается в силе). После шага возбуждение обоих действий стремится к нулю, поэтому  $P_8 = 0$ . Рассчитываем значение возбуждения  $P_6 = 30, P_8 = 45$ . СУТ выбирает нейрон увеличения нагрузки, т.е. нейрон (8). В новом положении  $P_1 = 40$  появляется информация об отказах, что приводит к возбуждению нейрона (2)  $P_2 = 20$ .

*Такт 3.*  $P_1 = 40, P_2 = 20, P_3 = 30, P_6 = 30$  – исходная информация для пересчёта. После пересчет уровней возбуждения:  $P_1 = 40, P_2 = 20, P_3 = 30, P_4 = 30, P_6 = 75, P_8 = 68$ . СУТ выбирает  $i$  – модель с уровнем  $P_6$ , который моделирует "уверенность". Её возбуждение увеличивается на 30 ед. Новое значение  $P_6 = 105$ .

В тактах 1 и 2 увеличение возбужденности не имело смысла, так как от этих моделей не отходит ни одной связи, а уровни возбужденности сбрасывались до нуля.

*Такт 4.* В предыдущем такте шаг не произведён, поэтому возбужденность  $i$  – моделей (1) и (2) не изменяется, и возбуждаемость модели (8) не сбрасывается. Таким образом, в исходе имеем:

$P_1 = 40, P_2 = 20, P_3 = 30, P_4 = 30, P_6 = 105, P_8 = 68$ . После пересчёта СУТ:  $P_1 = 40, P_2 = 20, P_3 = 30, P_4 = 45, P_5 = 11, P_6 = 73, P_8 = 190$ .

При определении величины, например  $P_6$ , необходимо на этот раз уменьшить  $\alpha, K_H$  до 0,3, поскольку в предыдущем такте эта  $i$  – модель была выбрана СУТ.

На 4-ом такте СУТ выбирает действие  $P_8$  – "увеличить нагрузку", и модель находится в новом восприятии среды. Далее такты повторяются.

Результаты расчёта сведены в табл. 2.5.1.

Таблица 2.5.1

Сводка результатов расчётов.

$i \backslash \tau$	$\tau_1$	$\tau_2$	$\tau_3$	$\tau_4$	$\tau_5$	$\tau_6$	$\tau_7$	$\tau_8$	$\tau_9$	$\tau_{10}$	$\tau_{11}$	$\tau_{12}$
1	0	20	40	40	60	60	80	80	100	100	120	120
2	0	0	20	20	40	40	80	80	120	160	160	200
3	30	30	30	30	30	30	30	30	30	30	30	30
4	0	0	30	45	85	102	200	130	<b>276</b>	189	<b>362</b>	250
5	0	0	0	11	21	33	48	70	62	94	76	115
6	0	30	<b>105</b>	73	<b>155</b>	100	<b>158</b>	165	200	216	238	250
7	0	0	0	0	24	44	55	63	74	142	90	174
8	<b>45</b>	<b>45</b>	68	<b>190</b>	100	<b>152</b>	112	<b>200</b>	146	<b>318</b>	170	<b>330</b>
	↑	↑		↑		↑		↑		↑		↑

Примечание:

 $(\tau)$  – время; $(i)$  – модель нейрона;↑ – моменты выполнения действий  $i$ –моделью;Жирным шрифтом выделены максимальные значения возбуждений в моменты  $\tau$ ,  $\tau + n$ .

Действие модели выполняется, когда степень возбуждения имеет максимальное значение для управляющих нейронов (8). Постепенно строится оптимальная траектория пуска оборудования (рис. 2.5.6.).




Рис. 2.5.6. Обобщающая зависимость для оптимальной траектории пуска

Оптимальная кривая изменения нагрузки при пуске оборудования имеет ступенчатый вид (подъем, выдержка). Во время выдержек модель

“ожидает”: случится поломка или нет. После выдержки “страх” поломки уменьшается.

Нейромодель, таким образом, имитирует действия оператора, ожидающего, не произойдет ли недопустимое повышение вибраций (опасность поломки) при увеличении нагрузки. В моменты времени  $\tau_8 - \tau_9$ ,  $\tau_{10} - \tau_{11}$ , когда модель имитирует снижение страха поломки у оператора, происходит процесс изменения нагрузки.

Форма траектории изменения нагрузки зависит от  $K_n$  (угловой коэффициент усиления),  $\alpha$ ,  $r_i$ ,  $\tilde{r}_i$ .

Для коррекции траектории в первую очередь изменяют связи  $r_i$ , затем коэффициенты  $\alpha$  и  $K_n$ , чтобы приблизить эту кривую к реальной.

Реализованная нейронная модель относится к детерминированным моделям, в которых роль каждого нейрона заранее определена. Это предоставляет большие возможности, по сравнению с моделями “чёрный ящик”, в определении желаемых характеристик управления. В частности, для рассмотренного случая можно учесть индивидуальные характеристики “Уверенности”, “Опасности”, назначая оптимальную степень производственного риска. Следовательно, нейромодель может быть применена не только в рассмотренном случае, но и для других технологических ситуаций.

## **2.6. Моделирование систем автоматического регулирования (САР) и автоматизированных систем автоматического управления (АСУ ТП) с помощью нейросетей**

Элементы, составляющие САР и АСУ ТП классифицируются по их динамическим свойствам, определяющим характер переходных процессов, возникающих в этих элементах при типовом изменении входной величины. Принято для синтеза САР и АСУ ТП выбирать такие элементарные звенья, которые по физическим свойствам уже не могут быть разделены на более простые. Пользуясь правилами составления систем, можно из типовых элементарных звеньев составить сколь угодно сложную систему и рассчитать её динамические свойства, зная характеристики каждого звена. К числу типовых элементарных звеньев относятся усилительное, апериодическое, колебательное, интегрирующее, дифференцирующее звенья и звено чистого запаздывания.

Примерами усилительных звеньев могут служить рычажные передаточные механизмы приборов, зубчатые редукторы, электронные усилители и рабочие органы (краны, заслонки) САР.



В качестве примера колебательных звеньев можно привести электрический контур, состоящий из резистора, индуктивности и конденсатора, мембранный исполнительный механизм, поплавковый дифференциальный манометр и т.д.

К типовым элементарным звеньям относится большинство первичных датчиков-преобразователей технологической информации. При синтезе систем управления свойства технологических объектов также сводят к свойствам одного или нескольких звеньев.

Типовые звенья являются идеализированными и описываются линейными дифференциальными уравнениями с постоянными коэффициентами. Основными характеристиками являются:

- коэффициент передачи (усиления)  $k$ ;
- постоянные времени  $T_i$ ;
- время запаздывания  $\tau_{\text{зап}}$ .

Отсутствие надежных методик расчета названных параметров, их изменение во времени для реальных объектов управления и датчиков приводит к существенным ошибкам в определении переходного процесса для синтезируемых САР и АСУ ТП. Такие же трудности встречаются и при решении обратной задачи – определении коэффициентов звена по экспериментально полученной переходной характеристике [20].

Аналогия между свойствами элементарных звеньев и нейронами очевидна. Преодоление перечисленных трудностей и повышение точности расчета переходных процессов в нелинейных системах становится возможным при использовании нейросетей для моделирования свойств типовых звеньев.

Для решения динамических задач целесообразно применять нейросети с внутренними обратными связями между нейронами (рис. 2.6.1). Изменяя силу связей и их знак (положительный или отрицательный), возможно получать любые виды переходных процессов, в том числе колебательные расходящиеся процессы. Примером практической реализации таких нейросетевых структур служит программный пакет NNDT (Neural Network Development Tool (version 1.4)) [21], который предлагается использовать ниже в примерах для синтеза моделей типовых элементарных звеньев. При моделировании переходных процессов в звене находят веса  $W_i$ , которые являются аналогами параметров  $k$ ,  $T_i$ ,  $\tau_{\text{зап}}$ .




Рис. 2.6.1. Иллюстрация нейросетей, созданных в пакете NNDT:

а – упреждающая сеть с тремя входными узлами, двумя выходными узлами и одним скрытым слоем с пятью нейронами;

б – сеть возврата с двумя реальными входными узлами, тремя действительными выходными узлами и двумя обратными связями: одной от реального выхода, а другой от фиктивного выходного узла;

[1] – номер функции активации нейронов.

Особенности работы в пакете NNDT заключаются в следующем.

### 2.6.1. Обучение сети

Для обучения сети необходимо выполнить следующие действия. Создать свой файл с данными, который будет использоваться для обучения. При создании файла с данными необходимо колонки в файле разделять табуляцией или пробелами. Пример формата файла:

Колонки: 1	2	3
x	$f_1(x)$	$f_2(x)$
0	0	0
0.1	0.099833	0
0.2	0.198669	0
0.3	0.29552	0

Здесь  $x$  – вход сети,  $f_1$  и  $f_2$  – желаемые выходы. Количество строк равно количеству временных шагов.

Выбрать в меню файл установки:

File”, “New Setup”.

New Setup (новая установка) выбирает сеть только с одним входным узлом и одним выходным узлом. Если уже имеется установочный файл (файл с расширением “mlp”), открывайте “Open Setup”, который выводит общее диалоговое окно для выбора файла. Для каждого примера выбирается своя форма сети, с внутренними слоями, с обратной связью

или без них, а также выбирается любое количество входов и выходов сети.

Установить “Setup”, “Pattern file”.

Pattern File (файл-образец) – название файла выбирается в диалоговом окне. Количество строк заголовка, т.е. строки, которые не учитываются в начале файла, задаются ниже названия файла. Если пользователь хочет изменить содержание файла – образца между последовательными испытаниями, блок под названием Always reread file (всегда повторно считываемый файл) нужно выделить, чтобы обеспечить постоянное считывание файла. Названия ( $f_1$ ,  $f_2$ ,  $x$ ), место положения (колонки 1, 2 и 3 в файле) для входных и выходных переменных и их количество выбираются в первых колонках таблицы. В последней колонке задержки времени установлены на 0, который означает, что все переменные для одной модели считываются из одной строки файла, но если вы используете звено чистого запаздывания, то устанавливайте необходимые вам значения. Первичные блоки используются для выбора предварительной обработки данных в файле – образце или тестовом файле.

Выбрать в файле “Setup”, “Network configuration” обратные связи, скрытые слои, узлы в каждом слое, функции активации для скрытых узлов и узлов выхода. Количество узлов входа и выхода также можно задать, но изменить их можно только в окне установки файла – образца.

Выход узла в скрытом или входном слое рассчитывается через функцию активации узла, которая в качестве аргумента использует вход узла. Можно использовать четыре разных функции активации нейрона: стандартную (сигмоидную) для аргумента в пределах от 0 до 1

$$y = \frac{1}{1 + e^{-x}},$$

симметрическую (логарифмическую)

$$y = \frac{x}{|x|} \ln(1 + |x|),$$

линейную

$$y = x,$$

сигмоидную (для аргумента от -1 до 1)

$$y = -1 + \frac{2}{1 + e^{-x}} = \tanh\left(\frac{x}{2}\right).$$

Разные функции активации узла можно задать для каждого слоя в сети. Сигналы от узлов в выходном слое формируют выход сети.

Задать “Show”, “Network state” (состояние сети), которые показывают форму окна для исследования весов сети и активации узлов. Network weights (веса нейронов сети) меняются с помощью редактирования величин таблицы. Величины, указанные в таблице

округляются до третьей цифры. Перед обучением сети необходимо обнулить значения “Network weights” (“Verify”, “Close”).

Запустить сеть для обучения, нажав “Start”, затем “File” и “Save setup us” – для сохранения данных испытания.

Для контроля процесса предусмотрены опции: “Performance” – для графика заданных значений и полученных результатов, “Progress” – для графической презентации погрешности обучения по данным испытания, показываемой через каждый шаг итерации.

### 2.6.2. Применение сети

После того, когда получили файл со структурой обученной сети, необходимо изменить в окне “Pattern File Setup” название обучающего файла на название тестового файла. Тестовый файл служит для изучения реакции нейромодели на тестовый сигнал, например, единичную функцию Хевисайда.

При создании тестового файла с данными также необходимо колонки в файле-образце разделять табуляцией, но, кроме того, можно использовать пробелы в качестве разделителей колонок. В колонке, где записаны результаты, напротив каждого входящего значения следует поставить те значения, которые необходимо получить. Пример:

$x$  – выбирается как вход сети, а желаемые выходы  $f_1$  и  $f_2$ .

$x$	$f_1(x)$	$f_2(x)$
0	0	0
0.1	0	0
0.2	0	0
0.3	0	0

*Output file* – (файл выхода) обычно используется для представления результатов. Этот файл необходимо создать, но в нем никаких данных записывать не надо. Для удобства последующей обработки, заранее выбирайте необходимое расширение для файла. В окне “Output file setup” выберите названия файла выхода, включив строку «Писать выходной сигнал сети в файл».

Далее необходимо включить опции “Show”, «Network State». В “Network weights” подставляют значения нужного коэффициента (“Verify”, “Close”).

Поскольку сеть уже обучена, переход в режим расчета переходного процесса осуществляется выполнением отключения опции “Train net”.

Запуская далее сеть нажатием кнопки “Start”, наблюдают во время запуска высвечиваемую информацию о процессе расчета переходного процесса.

### 2.6.3. Рекомендации пользователю для работы с файлами NNDT

Практически единственным неудобством работы в пакете NNDT является стыковка результатов расчета с программным обеспечением Microsoft Office. Рекомендуемый ниже вариант работы с файлами позволяет избежать трудности такой стыковки применительно к Excel.

Создание файла-образца для обучения нейросети проводят по следующему алгоритму.

1. Создать файл в FAR с расширением \*.dat (ap1.dat) .
2. Открыть файл в EXCEL.
3. Задать шкалу времени ( $\tau = 1..50$ ) в первой колонке.
4. Набрать формулу зависимости переходной характеристики во второй колонке( $Y = 1 - E^{-0,1\tau}$ ).
5. Произвести расчет выходной величины (Y).
6. Воспроизвести в первой колонке единичную функцию ( $X = 1$ ).
7. Сохранить файл.
8. Открыть файл в FAR.
9. Изменить формат данных файла, путем замены “,” на “.”.
10. Сохранить файл.

### 2.6.4. Пример реализации расчета переходного процесса нейромодели апериодического звена (1-го порядка)

1. Загрузить сеть NNDT.
2. Открыть файл с обученной моделью сети (ap1.mlp).
3. Изменить в окне “Pattern File Setup” название файла (ap1.dat) на название тестового файла (Тестовый.dat).
4. Открыть окно “Show”, «Network State». В “Network weights” подставить значения нужных параметров весов ( $W1 = 4,93E^{-2}$ ;  $W2 = 5,04E^{-2}$ ;  $W3 = 9,00E^{-1}$ )
5. Закрыть окно “Verify”, “Close”.
6. Отключить “Train net” (опцию обучения).
7. Нажать “Start”. Во время запуска будет высвечиваться информация о процессе испытания. Зафиксировать данную информацию. График результатов посмотреть в “Performance” и проверить в выходном файле.

Содержание используемых файлов для апериодического звена 1-го порядка представлено в табл. 2.6.1.

Таблица 2.6.1

Содержание файлов для нейромодели апериодического звена

Шаг по времени	Файл Ap1.dat		Файл Тестовый.dat		Файл Ap1.xls
	x	y	x	y	y(net)
	0	0	0	0	0
1	0	0.05	1	0	0,058148189
2	1	0.18	1	0	0,152063928
3	1	0.26	1	0	0,236564322
4	1	0.33	1	0	0,31259329
5	1	0.39	1	0	0,381000118
6	1	0.45	1	0	0,442548949
7	1	0.50	1	0	0,497927319
8	1	0.55	1	0	0,547753836
9	1	0.59	1	0	0,59258509
10	1	0.63	1	0	0,632921872
11	1	0.67	1	0	0,669214767
12	1	0.70	1	0	0,701869186
13	1	0.73	1	0	0,731249898
14	1	0.75	1	0	0,757685103
15	1	0.78	1	0	0,781470097
16	1	0.80	1	0	0,802870571
17	1	0.82	1	0	0,822125581
18	1	0.83	1	0	0,839450217
19	1	0.85	1	0	0,855038005
20	1	0.86	1	0	0,869063068
21	1	0.88	1	0	0,881682075
22	1	0.89	1	0	0,893035988
23	1	0.90	1	0	0,903251636
24	1	0.91	1	0	0,912443133
25	1	0.92	1	0	0,920713154
26	1	0.93	1	0	0,92815408
27	1	0.93	1	0	0,93484903
28	1	0.94	1	0	0,940872791
29	1	0.94	1	0	0,946292651
30	1	0.95	1	0	0,951169153
31	1	0.95	1	0	0,955556771
32	1	0.96	1	0	0,959504516
33	1	0.96	1	0	0,963056488
34	1	0.97	1	0	0,966252363
35	1	0.97	1	0	0,969127842
36	1	0.97	1	0	0,971715046
37	1	0.98	1	0	0,974042874
38	1	0.98	1	0	0,97613733
39	1	0.98	1	0	0,978021811
40	1	0.98	1	0	0,979717366
41	1	0.98	1	0	0,981242937
42	1	0.99	1	0	0,982615565
43	1	0.99	1	0	0,983850582
44	1	0.99	1	0	0,984961785
45	1	0.99	1	0	0,985961587
46	1	0.99	1	0	0,986861155
47	1	0.99	1	0	0,987670539
48	1	0.99	1	0	0,988398779
49	1	0.99	1	0	0,989054012
50	1	0.99	1	0	0,989643555

## 2.6.5. Параметры нейромоделей типовых звеньев

Аналогично вышеприведённому примеру были созданы нейромодели типовых элементарных звеньев. В таблицах приведены функциональная зависимость, параметры весовых коэффициентов нейронов и список файлов с исходной информацией. На рис. 2.6.1. – 2.6.11. показаны виды схем нейросетей и переходные процессы для каждого звена.

### Усилительное звено

#### Параметры усилительного звена

Функциональная зависимость	Параметры	<u>Список</u> <u>файлов</u>
$Y = kX$	$W1 = 2,16 e^{-15}$ $W2 = 1,00 e^0$	Pr.dat Pr.mlp Prtest.dat Pr.xls




Рис. 2.6.1. Схема нейросети для моделирования усилительного звена




Рис. 2.6.2. Переходная характеристика для усилительного звена

## Апериодическое звено 1-го порядка

### Параметры апериодического звена 1-го порядка

Функциональная зависимость	Параметры	Список файлов
$Y = 1 - e^{-0,1X}$	$W1 = 4,93 e^{-2}$ $W2 = 5,04 e^{-2}$ $W3 = 9,00 e^{-1}$	Ap1.dat Ap1.mlp Тестовый.D АТ Ap1.xls




Рис. 2.6.3. Схема нейросети для моделирования апериодического звена 1-го порядка

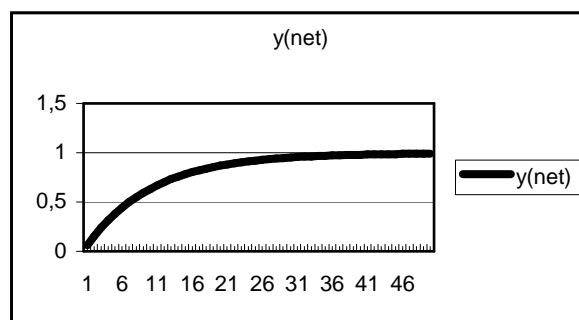


Рис. 2.6.4. Переходная характеристика для апериодического звена 1-го порядка



## Апериодическое звено 2-го порядка

Параметры апериодического звена 2-го порядка

Функциональная зависимость	Параметры	Список файлов
$Y = 1 - (T_3 / (T_3 T_4)) * e^{-\tau / T_3} + (T_4 / (T_3 - T_4)) * e^{-\tau / T_4}$	$W1 = 5,00 e^{-2}$ $W2 = 3,61 e^{-2}$ $W3 = 9,12 e^{-1}$ $W4 = -3,9 e^{-1}$ $W5 = 5,64 e^{-3}$ $W6 = -2,24 e^{-2}$ $W7 = 1,53 e^{-2}$ $W8 = 7,54 e^{-2}$	10.dat Ap2.mlp Тестовый.D AT 10.xls




Рис. 2.6.5. Схема нейросети для моделирования апериодического звена 2-го порядка




Рис. 2.6.6. Переходная характеристика для апериодического звена 2-го порядка

## Колебательное звено

### Параметры колебательного звена

Функциональная зависимость	Параметры	Список файлов
$Y = k[1 - e^{-\alpha^T * (\cos \omega t + \alpha / \omega * \sin \omega t)}]$	$W1 = 5,00 e^{-2}$ $W2 = 3,61 e^{-2}$ $W3 = 9,12 e^{-1}$ $W4 = -3,90 e^{-1}$ $W5 = 5,64 e^{-3}$ $W6 = -2,24 e^{-2}$ $W7 = 1,53 e^{-2}$ $W8 = 7,54 e^{-2}$	Koleb.dat Koleb.mlp Тестовый.DAT Koleb.xls

Схему нейросети для моделирования колебательного звена (см. рис. 2.6.5.).




Рис. 2.6.7. Переходная характеристика для колебательного звена

## Интегрирующее звено

### Параметры интегрирующего звена

Функциональная зависимость	Параметры	Список файлов
$Y = k_1 \cdot \tau$	$W1 = 4,96 e^{-1}$ $W2 = 5,04 e^{-1}$ $W3 = 1,00 e^0$	ii.dat ii.mlp Тестовый.dat ii.xls

Схему нейросети для моделирования интегрирующего звена (см. рис. 2.6.3.).




Рис. 2.6.8. Переходная характеристика для интегрирующего звена

### Дифференцирующее звено (реальное)

#### Параметры дифференцирующего звена

Функциональная зависимость	Параметры	Список файлов
$Y = e^{-0,1\tau}$	$W1 = 9,10 e^{-1}$ $W2 = -9,10 e^{-1}$ $W3 = 9,05 e^{-1}$	Rd.dat Rd.mlp Rdtest.dat Rd.xls

Схему нейросети для моделирования дифференцирующего звена (см. рис. 2.6.3.).




Рис. 2.6.9. Переходная характеристика для дифференцирующего звена

## Звено чистого запаздывания

### Параметры звена чистого запаздывания

Функциональная зависимость	Параметры	Список файлов
$Y = X(\tau - \tau_{\text{зап}})$	$W1 = 0$ $(W1 = 0)$ $W2 = 0$ $(W2 = 1)$ $W3 = 1$ $(W3 = 0)$	Без обучения Zap.mlp Zaptest.dat Outp.xls




Рис. 2.6.10. Схема нейросети для моделирования звена чистого запаздывания




Рис. 2.6.11. Переходная характеристика для звена чистого запаздывания

В таблицах приняты следующие обозначения:

$X$  – входной сигнал;

$Y$  – выходной сигнал;

$\alpha$  – коэффициент демпфирования;

$\omega$  – угловая частота.

## **2.7. Применение нейросетей на фондовом рынке**

Современные тенденции и события на мировых фондовых и валютных рынках имеют сложный характер и неоднозначно сказываются на положении в системе фондовой торговли. Основными направлениями тенденций являются следующие. Роль фондовых рынков, несмотря на частые потрясения, постоянно возрастает. Для корпораций и правительств рынки являются мощнейшим рычагом мобилизации ресурсов, и отказываться от этого средства они не намерены. В развитии информационного обеспечения рыночных механизмов современные компьютерные технологии занимают ведущее место. В передовых дилинговых системах, применяемых в российской финансовой и банковской сферах, присутствуют элементы искусственного интеллекта. Приход на рынок большого числа непрофессиональных игроков вызывает оживление спроса на открытые компактные торговые системы, позволяющие моделировать рынок и принимать решения в режиме реальных торгов. Нейросетевые методы в торговых системах доказали свою эффективность и имеют широкое распространение в программах для прогноза, анализа и выработки рекомендаций участникам рынка.

Для пользователя, решившего применить нейросеть в своей торговой системе, одним из несложных и недорогих вариантов является пример объединения программного обеспечения MS Office, ExNP и Internet с целью создания нейроробота “Уникомпартнёр” (название инвестиционной компании, г.Екатеринбург).

Синтезированный на ПЭВМ по этой схеме нейроробот в режиме on line функционирует следующим образом. Данные, поступающие с биржи через одну из существующих систем передачи биржевых данных через Internet (для Excel работают опции “Данные”/”Внешние данные”/”Выполнить Web-запрос”), преобразуются в форматы сенсоров нейроробота. Заранее обученная на параметрах выбранной ценной бумаги нейросеть, оценивает полученную информацию и принимает решение о виде выбранной позиции. Приказ транслируется по компьютерной сети в брокерскую контору на монитор трейдера или на пит. После подтверждения трейдера или совершения транзакции нейроробот автоматически протоколирует события.

### **2.7.1. Особенности функционирования и отличия нейроробота “Уникомпартнёр”**

Могут быть реализованы следующие режимы функционирования нейроробота:

- работа в режиме Tick by Tick;

- режим диагностики рынка и советчика трейдера;
- режим прогноза в выбранном временном окне;
- режим синтеза модели обобщенного инвестора, противостоящего трейдеру в данный момент на рынке;
- режим факторного анализа цены;
- режим оценки компетентности трейдера в конкретной ситуации;
- режим обобщения коллективного опыта трейдеров компании.

К отличительным от других торговых систем особенностям можно отнести следующие функциональные элементы.

1. Применение составных нейронов на входе сенсоров нейроробота.
2. Использование обратной связи (“рефлексивности” по Дж.Соросу).
3. Оценка “новостного фона” с помощью процедуры экспертных оценок Саати.
4. Применение методики фундаментального анализа инвестиционной компании “Униконпартнёр”.
5. Объективная оценка компетентности рекомендаций нейроробота.

### **2.7.2. Подготовка входной информации для нейроробота “Униконпартнёр”**

Основные входные факторы, учитываемые при реализации режима диагностики рынка ценных бумаг приняты следующими.

1. Текущая рыночная цена ценной бумаги.
2. Изменение этой цены.
3. Фундаментальная оценка цены по методу “Униконпартнёра”.
4. Потенциал роста/падения.
5. Индекс РТС по данным рынка.
6. Индекс РТС по фундаментальной оценке “Униконпартнёра”.
7. Доходность Rus’07.
8. Риск изменения цены продукции.
9. Риск реструктуризации.
10. Риск ликвидности.
11. Риск управления.
12. Влияние конъюнктуры (“новостного фона”).
13. Предыдущие рекомендации нейроробота (или действия трейдера).

Названия лингвистических переменных, используемых инвестиционной компанией “Униконпартнёр” при анализе ситуации на рынке были приняты такими:

- для роста, падения цены: “резкий, ускоренный, большой, стабильный, низкий”;
- для изменения цены: “повышенное, пониженное”;
- для стабильной ситуации: “нейтральное, нормальное, среднерыночное”;
- для действий трейдера: “активно покупать, покупать, держать, продавать”.

Фундаментальные оценки цены определялись с помощью модели дисконтирования денежных потоков “Уникопартнёра”[22]. Суть подхода состоит в построении на основе финансовой отчетности компании ее финансовой модели и прогнозировании темпов роста свободных денежных потоков на ближайшие пять лет (фаза ускоренного роста) и последующий период (фаза стабильного роста). Затем эти денежные потоки приводятся к сегодняшнему дню, причем используемая при этом ставка дисконтирования состоит из двух частей: доходности российских еврооблигаций с погашением в 2007 году и премии за риск вложений в акции (equity risk premium). Например, ставка, которая использовалась для последнего расчета фундаментальных оценок на 14.06.2002, составляла 13,10% (8,10 + 5,00). Полученная таким образом чистая приведенная стоимость и являлась фундаментальной оценкой (fair value) капитализации компании.

Долгосрочные рекомендации для обучения выставлялись в зависимости от разницы между фундаментальной оценкой акции и ее текущей ценой. По мере сокращения этой разницы рекомендации изменялись с *Активно покупать* до *Покупать*, *Держать* и, наконец, *Продавать*. Ясно, что на разницу (в данной терминологии – Потенциал роста / падения) влияли три фактора: параметры финансовой модели, текущая цена и ставка дисконтирования, поэтому изменение любого из этих факторов приводило к повышению или понижению рекомендации.

При формировании долгосрочных обучающих рекомендаций помимо фундаментальной привлекательности той или иной акции необходимо учитывать ее ликвидность, отраслевые особенности компании, качество корпоративного управления. Поэтому учитывались и потенциальные факторы риска, которые могли повлиять на динамику цены в кратко- и среднесрочной перспективе.

Основные форматы данных, помещенные на лист “Данные” Excel и используемые в программном обеспечении нейроробота, представлены в табл. 2.7.1.

Таблица 2.7.1

## Входная информация для нейроробота “Уникомпартнёр”

Дата	Время	Ф.И.О. Эксперта-аналитика	Эмитент	Цена на начало периода, руб.	Изм. за период, %	Фундам. оценка, руб.	Потенциал роста / падения, %
14.06.02	13:00	Д.Казин	Газпром*	33,45	9,20%	27,8	-16,90%
15.11.02	9:00	Д.Казин	Газпром*	25,37	15,50%	47,87	88,70%
09.10.02	10:00	Д.Казин	Газпром*	21,97	-15,50%	38,47	75,10%
09.09.02	11:00	Д.Казин	Газпром*	25,99	-0,70%	36,89	41,90%
09.08.02	12:00	Д.Казин	Газпром*	26,17	-14,80%	25,86	-1,20%
14.06.02	13:00	Д.Казин	Газпром*	33,45	9,20%	27,8	-16,90%

Долгосрочная рекомендация	Предыдущая рекомендация	Причина изменения	Потенц. факторы риска	Индекс РТС по данным рынка, руб.	Индекс РТС фундаментальный, руб.	Доходность Rus '07 на начало периода
<b>Продавать</b>	<i>Продавать</i>		ЦПр. + Рестр.	391,26	443,41	13,1
<i>Акт. покупать</i>	<i>Акт. покупать</i>		ЦПр.	358,65	575,22	11,46
<i>Акт. покупать</i>	<i>Покупать</i>		ЦПр.	334,06	493,66	12,9
<i>Покупать</i>	<i>Держать</i>	Изм. МДДП	ЦПр.	332,9	465,94	13,2
<i>Держать</i>	<i>Продавать</i>	Изм. Ц	ЦПр. + Рестр.	326,23	411,73	13,8
<b>Продавать</b>	<i>Продавать</i>		ЦПр. + Рестр.	391,26	443,41	13,1



Продолжение таблицы 2.7.1

1. Цена, руб						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Пониженная		Среднерыночная		Повышенная	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
33,45	21,97	33,45	21,97	33,45	21,97	33,45

2. Изменение цены за период, %						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Падение		Нейтральное		Рост	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
9,20%	-15,50%	9,20%	-15,50%	9,20%	-15,50%	9,20%

3. Фундаментальная оценка цены Униконпартнером, руб					
Граничные значения лингвистических переменных ФП					
Пониженная		Среднерыночная		Повышенная	
Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
<b>25,86</b>	<b>47,87</b>	<b>25,86</b>	<b>47,87</b>	<b>25,86</b>	<b>47,87</b>

4. Потенциал роста/падения,%						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Падение		Нейтральный		Рост	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
-16,90%	-16,90%	88,70%	-16,90%	88,70%	-16,90%	88,70%

Продолжение таблицы 2.7.1

5. Индекс РТС по данным рынка, руб						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Пониженный		Среднерыночный		Повышенный	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
391,26	326,23	391,26	326,23	391,26	326,23	391,26

6. Индекс РТС фундаментальный, руб						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Пониженный		Среднерыночный		Повышенный	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
443,41	411,73	575,22	411,73	575,22	411,73	575,22

7. Доходность Rus '07 на начало периода, %						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Пониженная		Среднерыночная		Повышенная	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
13,1	11,460	13,800	11,460	13,800	11,460	13,800

8. Риск изменения цены продукции, доли ед. вероятности						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Отсутствие		Пониженный		Повышенный	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
1	0,000	1,000	0,000	1,000	0,000	1,000

Продолжение таблицы 2.7.1

9. Риск реструктуризации, доли ед. вероятности						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Отсутствие		Пониженный		Повышенный	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
0	0,000	1,000	0,000	1,000	0,000	1,000

10. Риск изменения ликвидности, доли ед. вероятности						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Отсутствие		Пониженный		Повышенный	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
0	0,000	1,000	0,000	1,000	0,000	1,000

11. Риск изменения стиля корпоративного управления, доли ед. вероятности						
Значение для диагностики	Граничные значения лингвистических переменных ФП					
	Отсутствие		Пониженный		Повышенный	
	Мин.	Макс.	Мин.	Макс.	Мин.	Макс.
0	0,000	1,000	0,000	1,000	0,000	1,000

12. Прогноз эксперта на изменение цены под влиянием политической,экономической и другой конъюнктуры, доли ед. вероятности		
Понижение	Не изменится	Повышение
0,349	0,252	0,392
На основе экспертных оценок из файла "Конъюктура.xls" !		

Предыдущие данные				
13. Предыдущие рекомендации эксперта в виде их доли ед. вероятности принадлежности к лингвистическим переменным				
Активно продавать	Продавать	Держать	Покупать	Активно покупать
0	1	0	0	0
То же для справки, в виде предыдущих рекомендаций нейроробота				
0	0,9	0,1	0	0

Обозначения в табл. 2.7.1:

ЦПр. - риск, связанный с изменением цен на продукцию компании;  
 Рестр. - риск, связанный с реструктуризацией компании;  
 Ликв. - риск, связанный с низкой ликвидностью акций;  
 КУ - риск, связанный с корпоративным управлением.

Изм. Ц - изменение цены акций;  
 Изм. СД - изменение ставки дисконтирования;  
 Изм. МДДП - изменение модели дисконтированных денежных потоков.

На листе “Адаптация” выполнены построения ФП входных нейронов. Пример такого построения показан на рис. 2.7.1.

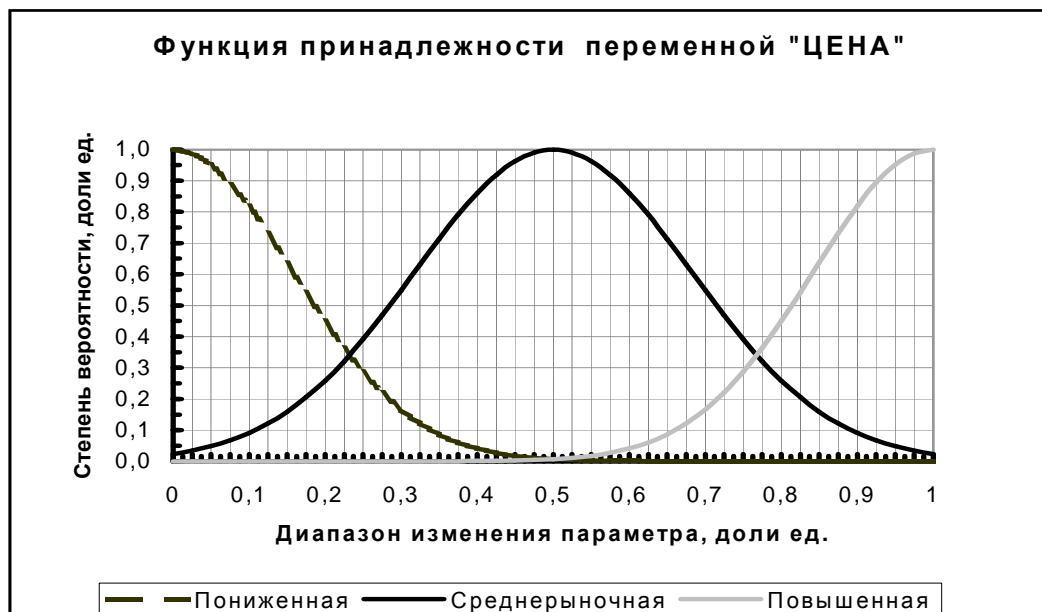


Рис. 2.7.1. Формирование лингвистической переменной “Цена”

Число переменных принято равным 41: 36 входных и 5 выходных. Все входные переменные имеют ФП, предварительно адаптированные к данной финансовой ситуации на рынке.

### **2.7.3. Компьютерная формализация “новостного фона”**

Пример текущей информации о новостях, взятый с открытого сайта инвестиционной компании “Уникомпартнер”[22] и представляющий постоянно обновляемый в часы работы компании список событий, выглядит следующим образом:

- 20:13 Г.Шредер в конце недели обсудит иракский вопрос с Т.Блэром и Ж.Шираком.
- 20:12 Г.Греф: потенциал роста экономики Российской Федерации составляет 6-10% в год.
- 19:49 Комментарий к закрытию рынка.
- 19:36 Против NYMEX выдвинуто обвинение в попытке монополизации американского фьючерсного рынка нефти.
- 19:19 Действующий фонд ОАО "Оренбургнефть" на начало 2003 г. составил 2 664 скважины.
- 19:05 С 1 января переименованы региональные филиалы ОАО "Ростелеком".
- 18:24 Белоруссия округляет розничные цены, изымая из обращения купюры в 1 руб.
- 18:17 Свежий обзор - ОАО "Пивоваренная компания Балтика".
- 18:15 МНС недовыполнило задание по сбору налогов в бюджет.
- 18:14 Добыча угля в России в 2002 году сократилась на 12,1%.
- 18:06 Еврокомиссия установила крайний срок проведения программы оздоровления государственного бюджета Германии.
- 18:05 Минсельхоз РФ: В ходе зерновых интервенций государство закупило почти 2,5 млн т зерна урожая 2002г. на 4,307 млрд руб.
- 17:08 Число абонентов сотовой связи в РФ приблизилось к 18 млн.
- 16:59 МНС за январь-ноябрь недовыполнило сбор налогов в бюджет РФ на 45 млрд. руб.
- 16:51 "Аэрофлот" увеличил чистую прибыль за 9 месяцев 2002 г. в 3,5 раза.
- 16:44 Бразилия намерена стать ядерной державой.
- 16:43 Комментарий к середине торгового дня.
  
- 12:32 Нью-Йоркскую товарную биржу обвинили в нарушении антимонопольного законодательства.
- 12:23 Комментарий к открытию рынка.
- 12:02 На ГНКМ «Заполярье» начинается третий, последний этап, обустройства месторождения.
- 11:49 Экономическая эффективность НИОКР в ОАО "Сургутнефтегаз" в 2002 г. составит около 2,4 млрд руб.
- 11:18 Банки Венесуэлы присоединились ко всеобщей забастовке.
- 10:37 Администрация Буша положительно относится к планам ОПЕК.
- 10:15 Населению Австрии угрожает дефолт.
- 9:55 Премьер Японии считает энергетику перспективной сферой
- 9:52 Алексей Кудрин намерен ускорить экономический рост сотрудничества с Россией.
- 9:51 МВФ обнародовал план по созданию глобальной системы банкротств.
- 9:46 Главные эмитенты облигаций открывают новый год.
- 9:41 В 2002 г. ОАО "Первоуральский новотрубный завод" произвело товарной продукции на сумму более 3 млрд руб.

9:27 АвтоВАЗ увеличил экспорт автомобилей.

9:25 Daily Telegraph: Британский бизнес не торопится призывать к присоединению страны к единой европейской валюте.

9:16 "Северсталь" в 2002 году увеличила выпуск проката на 5,6%.

9:00 Доброе утро! Компания "Уником Партнер" приветствует Вас и желает Вам удачного дня!

Учет “новостного фона” был введен по следующим причинам.

*Влияние новостей.* Исследования, проводимые главным образом для рынков Forex, продемонстрировали статистически достоверную зависимость между появлением новой информации от службы новостей Money Market Headline News и величинами волатильности прибыли и спреда (волатильность и спред вычислялись для пятиминутных интервалов). Как и следовало ожидать, активность в потоке новостей увеличивает условную волатильность как прибыли, так и спреда [23].

*Что есть новость.* Новостью можно назвать такую информацию о событии, которая "значительно" отличается от ожидаемой. Очевидно, таким образом, что понятие "новости" может стать объективным для рынка только если эта новость окажется таковой для большинства участников рынка. Проводились исследования, в которых измерялась частота прихода сообщений в информационной системе Reuters, с помощью оценки величин относительных частот встречаемости различных слов и словосочетаний и установления корреляционных зависимостей между появлением наиболее часто встречающихся слов и изменениями в ценах покупки и продажи на рынке Forex. Наиболее очевидный способ измерения информативности ("новизны") сообщения как раз и состоит в оценке влияния этого сообщения на цены. Отдельный вопрос: каким именно формальным способом оценивается это влияние? Кроме такого подхода, активность в потоке новостей предлагалось оценивать числом котировок в единицу времени, размерами спреда или средним временем между соседними трейдами.

При разработке нейроробота учтены все вышеперечисленные особенности. Обработка новостей производилась экспертным методом с помощью формализованной процедуры экспертных оценок Саати (см. п.1.5). Согласно этой процедуре были заданы

**Критерии:**

1.	<b>Политика</b>
2.	Экономика
3.	Финансы
4.	Зарубежные рынки
5.	Конфиденциальная информация
6.	Астрологический прогноз

**Альтернативы:**

1.	Понижение цены
2.	Нет влияния
3.	Повышение цены

Основные математические параметры, принятые в программе:

Размер матрицы критериев, альтернатив	6	3
Случайная согласованность	1,24	0,58

Определены информационное содержание критериев, пределы шкалы экспертных оценок и структура самой шкалы, по которой оценивалась каждая новость.

N,п/п	Критерии	Информационное содержание	Альтернативы		
			Понижение цены	Нет влияния	Повышение цен
1	Политика	Отставка президента по собств.жел, баллы эксперта	7	1	1
2	Экономика	Рост ВВП,%	0,1	0,1	0,5
3	Финансы	Снижение ставки рефинансирования, %	1	1	5
4	Зарубежные рынки	Рост инд, S&P,%	1	1	10
5	Конфиденциальная информация	Отсутствует	1	1	1
6	Астрологический прогноз	Способствует торговле, баллы эксперта	1	1	3

**Шкала относительной важности**

Интенсивность относительной важности, баллы	Определение	Пояснение
1	Равная важность	Оба объекта вносят одинаковый вклад в достижение поставленной цели
3	Умеренное превосходство одного над другим	Есть некоторые основания предпочесть один объект другому, но их нельзя считать неопровержимыми

5	Существенное превосходство	Существуют важные свидетельства того, что один из объектов более важен
7	Значительное превосходство	
9	Очень сильное превосходство	Имеются неопровержимые основания, чтобы предпочесть один объект другому
2,4,6,8	Промежуточное решение между двумя соседними суждениями	Превосходство одного из объектов очевидно, что не может вызвать ни малейшего сомнения
		Используются тогда, когда выбор между двумя соседними числами вызывает затруднения

Вначале экспертом выполнялось попарное сравнение критериев, используя в Excel удобный механизм связи графического интерфейса с данными электронной таблицы. Результаты этого сравнения сводились в отдельную матрицу весовых коэффициентов важности. Затем аналогично сравнивались альтернативы по каждому критерию и таким же способом формировалась матрица окончательных результатов экспертных оценок новости. Найденные глобальные веса альтернатив записывались в файл “Конъюнктура.xls” и поступали на соответствующие сенсоры нейросети. Для определения степени насыщенности (СН) рынка ценных бумаг экспертным методом, рекомендуется установленная зависимость между лингвистической переменной “спрос” и величиной СН:

Лингвистическая переменная “спрос”	СН
1. Затоваривание	1,000-0,975
2. Очень низкий	0,975-0,950
3. Низкий	0,950-0,925
4. Пониженный	0,925-0,900
5. Сбалансированный	0,900-0,750
6. Повышенный	0,750-0,650
7. Высокий	0,650-0,500
8. Очень высокий	0,500-0,350
9. Ажиотажный	0,350-0,000

Примеры результатов формирования экспертных матриц приводятся ниже.





## ОСНОВНЫЕ РЕЗУЛЬТАТЫ ЭКСПЕРТНОГО ВЫБОРА

Альтернативы	Критерии					
	Политика	Экономика	Финансы	Зарубежные рынки	Конфиденциальная информация	Астрологический прогноз
	Численное значение вектора приоритета					
	0,236640	0,131630	0,158342	0,128345	0,287510	0,057533
Понижение цены	0,684737	0,270652	0,317876	0,326294	0,129574	0,426670
Нет влияния	0,161836	0,206015	0,351732	0,342197	0,136026	0,135057
Повышение цены	0,153426	0,523334	0,330392	0,331509	0,734399	0,438273

**Рекомендация:** Следует остановить свой выбор на альтернативе с максимальным значением глобального приоритета =

Достигнутая степень компетентности:

**Достаточная**

Относительная погрешность результата:

Не более 35%

Уровень качества результата:

**Идентификация рыночной ситуации при выборе**



## 2.7.4. Обучение нейроробота “Уникомпартнёр” и нейродиагностика рынка ценных бумаг

На листе “Обучение” формируется выборка данных и рекомендаций для обучения нейроробота. В неё включена текущая информация из временного окна на листе “Данные”, а также другая необходимая для обучения, по мнению эксперта, информация из предыдущих торговых сессий.

На листе “Диагностика” осуществляется подключение обученной нейросети, например ExNP . Пример такой сети для ценной бумаги “GAZP” представлен на рис. 2.7.2.

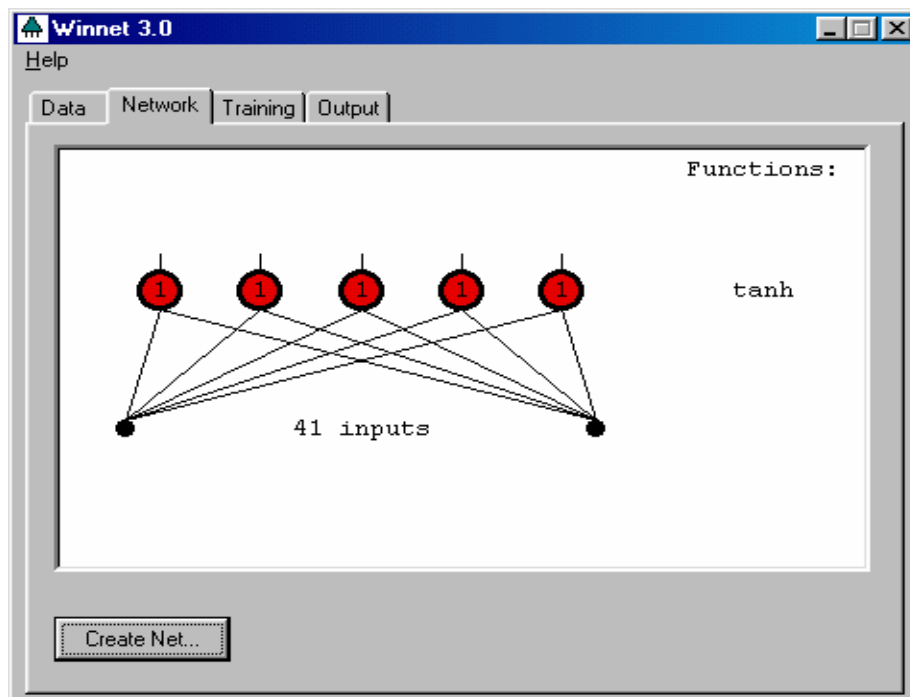


Рис. 2.7.2. Нейросеть для диагностики финансовой ситуации на фондовом рынке

На листе “Протокол” создана форма для записи в файл и последующей распечатки. Рекомендуемый вид протокола приведен ниже.

## Диагностика рынка ценных бумаг с помощью нейроробота Уникомпартнер-1

Дата анализа: 14.06.02  
N варианта: GAZP  
Исполнитель: Д. Казин  
Организация: Уникомпартнер

### Основные параметры и факторы

1. Цена, руб	33,45
2. Изменение цены на период, %	9,20%
3. Фундаментальная оценка цены, руб	27,8
4. Потенциал роста/падения, %	-16,90%
5. РТС по данным рынка	391,26
6. РТС, фундаментальная оценка	443,41
7. Доходность RAS '07, %	13,1
8. Риск изменения цены продукции	1
9. Риск реструктуризации	0
10. Риск ликвидности	0
11. Риск изменения стиля управления	0
12. Влияние конъюнктуры	ПНЖ= 0,349
13. Предыдущие рекомендации эксперта:	АПРД ПРД
	0 1

### Результаты диагностики

Вероятности рекомендаций:				
1. <i>Акт. Продавать</i>	0,963			
2. <i>Продавать</i>	0,031			
3. <i>Держать</i>	0,003			
4. <i>Покупать</i>	0,003			
5. <i>Акт покупать</i>	0,000			
	НЕЙТР= 0,252	ПВШ= 0,392		
	ДРЖ	ПКП	АПКП	
	0	0	0	

### Параметры качества диагностики:

Относит. погрешность диагностики: 16%  
Степень компетентности нейроробота: Хорошая  
Уровень качества диагностики: Оптимизация

### Рекомендации нейромодели:

Активно продавать!

### Заключение эксперта:

### Подпись эксперта:

### 2.7.5. Алгоритм функционирования нейроробота “Уникомпартнёр”

Компьютерная программа, поддерживающая функционирование нейроробота для Excel предусматривает следующие операции.

1. Ввод информации “Уникомпартнера”.
2. Экспертная обработка новостей.
3. Заполнение листа “Данные”.
4. Передача данных на лист “Диагностика”.
5. Копирование данных с листа “Диагностика” на лист “Обучение”.
6. Формирование выборки для обучения нейроробота.
7. Диагностика рынка и формирование протокола.

Как видно, алгоритм нейроробота “Уникомпартнёр” аналогичен алгоритму нейроробота “Партнер мастера”, принцип действия которого рассмотрен ранее (см. п. 2.4).

### 2.7.6. Факторный анализ рыночной позиции трейдера с помощью нейроробота

Обученную нейросеть робота можно “вскрыть” для весовой оценки различных факторов на получаемые рекомендации. Для этого в режиме “Диагностика” на входы сети подают специально сформированную матрицу. Пример такой матрицы для ФП фактора “Цена” дан ниже.

1. Цена			Идентификаторы входа
Значения ФП			
Пониженная	Среднерыночная	Повышенная	
Цпнж	Цср	Цпвш	
1,000	0,000	0,000	Цпнж
0,000	1,000	0,000	Цср
0,000	0,000	1,000	Цпвш

Произведя расчет вероятностей выходных сигналов нейросети, строят факторную диаграмму для весовых коэффициентов. Факторные диаграммы приведены на рис 2.7.3 –2.7.4. Анализ диаграмм несложен. Например, рекомендация “Продавать” наиболее подвержена влиянию величин “Фундаментальная цена среднерыночная” ( $\PhiЦ_{cp}$ ) и “индекс РТС фундаментальный пониженный” ( $РТС_{пнж}$ ), для которых коэффициенты линейной чувствительности (регрессии)  $\beta_i$  максимальны по абсолютной величине и равны соответственно 0,844 и 0,851. Поэтому трейдер, следуя рекомендациям нейроробота об открытии позиции на продажу акций, должен, в первую очередь, анализировать информацию об этих факторах для конкретной рыночной ситуации.

Так как указанные величины определяются с помощью математической модели “Уникомпартнера”, то к надежности расчетов по этой модели также предъявляются повышенные требования.

Для рекомендации “Активно покупать” максимальное абсолютное значение  $\beta_i$ , равное 0,940, согласно рис. 2.7.4, имеет место для параметра “Потенциал падения”  $ПТЛ_{пад}$ . Трейдер, принявший решение о покупке акций, в первую очередь, обращает внимание на динамику этого фактора.

Действие обратной связи (“рефлексивности” по Дж. Соросу [25]) можно выяснить, рассмотрев значения коэффициентов  $\beta_i$  для входных факторов нейросети в табл. 2.7.2.

Таблица 2.7.2

Влияние обратной связи на рекомендации нейроробота

Идентификаторы нейронов	Коэффициент регрессии	
	ПРД	АПКП
АПРДвх	0,102	-0,366
ПРДвх	0,200	0,214
ДРЖвх	-0,584	-0,531
ПКПвх	-0,337	0,346
АПКПвх	0,097	-0,201

Максимальные по абсолютной величине значения коэффициентов регрессии факторов имеют место для входной связи нейрона “Держать” (идентификатор  $ДРЖ_{вх}$ ). Следовательно, прогноз ожиданий инвесторов заключается в переходе именно на эту рыночную позицию.




Рис. 2.7.3. Весовая диаграмма выходного нейрона “ПРОДАВАТЬ”




Рис. 2.7.4. Весовая диаграмма выходного нейрона “АКТИВНО ПОКУПАТЬ”

### 2.7.7. Работа нейроробота во время дневной торговой сессии

Пример действий нейроробота по выработке рекомендаций трейдеру на открытие и закрытие позиции в режиме прогноза финансовой ситуации показан на рис. 2.7.5 и рис. 2.7.6, где приведены временной и объемный профили рынка ММБВ [Акции ЛУКОЙЛ (1 уровень)]. Дневная торговая сессия отличается повышенной динамичностью и её анализ наиболее интересен. Основными параметрами сессии были следующие:

Начало сессии – 10:30:26 AM;  
Конец сессии – 18:44:59 AM;  
Общий объем торгов – 408252 шт.;  
Цена открытия – 496,50 руб.;  
Цена закрытия – 485,99 руб.;  
Мин. цена – 485,60 руб.;  
Макс. цена – 498,80 руб.

После открытия торгов, нейроробот дважды выдавал рекомендации на смену позиций: метки времени 377, 504 в первом (по ходу сессии) случае и 1040,1242 – во втором. Важно, что эти периоды совпали с имевшими место наибольшими локальными изменениями цены: мин. - 488,1 руб.; макс. - 494,0 руб. (сред 5,9 руб.) в первом случае и мин. - 486,1 руб.; макс. - 488,75 руб. (сред 2,65 руб.) – во втором. Анализ изменения объемов торгов также показал локальное возрастание активности участников рынка в эти промежутки времени. В первом случае локальный объем торгов составил 93720 шт., а во втором – 77919 шт. акций соответственно.

Однако, по сравнению с общим объемом торгов в этот день, указанные локальные показатели объемов составляли лишь 23% и 19% для каждого случая соответственно. Это говорит о том, что участники рынка в настоящее время не имеют достаточно компетентных прогнозов, учитывающих новостной фон, или применяемые ими торговые системы с нейросетями недостаточно эффективны. В связи с этим использование предлагаемого нейроробота “Уникомпартнер” на фондовом рынке представляется перспективным. Торговля во время дневных сессий подвержена большему, по сравнению с более длительными промежутками времени, риску. Возможно для российского рынка более приемлемым является недельный период. Однако удлинение временного окна затрудняет процессы обучения и адаптации нейроробота, так как для них требуется большой (годовой и более) объем информации. Эти требования не всегда могут быть реализованы пользователем, поэтому рекомендуется временное окно оптимизировать к возможностям пользователя и рынка одновременно. Критерием такой оптимизации может служить заданная степень компетентности нейроробота.



## **2.8. Определение оптимальной цены продукции с помощью нейромаркетингового исследования**

Разнообразие функций маркетинга [26] отражает разносторонность маркетинговой деятельности, направленной в конечном счёте на доведение товара до сферы потребления и на удовлетворение потребностей покупателей. Сбор информации, оценочные и прогнозные расчёты, выполняемые для маркетинговых служб и руководства фирмы по их заказу, принято называть маркетинговым исследованием. *Маркетинговое исследование* – любая исследовательская деятельность, направленная на удовлетворение информационно-аналитических потребностей маркетинга. Маркетинговое исследование включает сбор, обработку, а также хранение информации о явлениях и процессах, анализ собранных материалов, получение теоретически обоснованных выводов и, наконец, прогнозирование. *Цель маркетингового исследования* – создать информационно-аналитическую базу для принятия маркетинговых решений и, тем самым, снизить уровень неопределённости, связанной с ними. В данном разделе рассмотрено маркетинговое исследование с помощью нейросети – нейромаркетинг. Здесь представлено определение оптимальной цены на керамическую плитку и влияние художественной ценности, качества дизайна, оригинальности и других факторов на её стоимость.

### **2.8.1. Предлагаемый метод определения оптимальной цены на облицовочную плитку**

Цена на плитку зависит от множества факторов (размеры, качество, художественное оформление и т.д.), а также от текущего соотношения между спросом и предложением на рынке, поэтому значение цены устанавливается, как правило, опытными экспертами. Однако, если мнения экспертов расходятся, то это приводит к существенному разбросу цен на плитку, что имеет место в действительности. Для того, чтобы учесть зависимость цены от различных факторов, а также обобщить мнения экспертов предлагается производить расчёт оптимальной цены с помощью компьютерной нейронной сети (интеллектуального робота). В этом случае нейронная сеть, моделирующая коллективный опыт экспертов при установлении цены, будет находить её оптимальное значение точнее, чем каждый эксперт в отдельности. Таким образом владелец обученной компьютерной нейронной сети получает информационное преимущество перед другими конкурентами на рынке.

В настоящее время (апрель 2003г.) на рынке Екатеринбурга представлена продукция более 15 производителей облицовочной плитки. Таким образом имеется существенная конкуренция между ними. В Екатеринбургских магазинах таких, как “Альфа керамика”, ”Бэст керамикс”, “Центр

керамики” и т.д. представлено большое разнообразие керамической плитки по качеству, художественному оформлению и размерам . В связи с этим имеется существенный разброс цен на неё (132- 1312 руб. за 1м<sup>2</sup> ). Отсюда не ясно, правильно ли установлена цена на плитку производителем. Неоптимальное установление продажной цены на облицовочную плитку может привести к потере прибыли. В случае недооценки продукции производитель теряет прибыль с каждого факта продажи. При переоценке прибыль уменьшается из-за снижения объёма продаж. Таким образом, является актуальной задача определения оптимальной цены на облицовочную плитку и проверка правильности установления этой цены производителями [27].

### **2.8.2. Реализация предлагаемого метода определения оптимальной цены**

В данной методике была применена компьютерная программа, содержащая нейронную сеть.

#### **Исходная информация для обучения нейронной сети**

- 1.1. Количество обследованных магазинов – 14 .
- 1.2. Количество выбранных факторов, влияющих на цену плитки – 7 :
  - Длина;
  - Ширина;
  - *Качество дизайна, оригинальность;*
  - *Художественная ценность композиции;*
  - Удобство;
  - Наличие декора;
  - Наличие бордюра.
- 1.3. Используемая шкала экспертных оценок для характеристики художественных параметров плитки (баллы).
  - 1– Посредственное оформление .
  - 3– Удовлетворительный внешний вид.
  - 5– Хорошая привлекательность .
  - 7– Большая художественная ценность .
  - 9– Высокая степень оригинальности .
  - Наличие декора (бордюра) – 1, отсутствие –0.

Сводная табл. 2.8.1. исходной информации для обучения нейронной сети представлена ниже .

Таблица 2.8.1.

Определение нейрочены на облицовочную плитку  
(обучающий пример)

№ п/п	Ширина, мм	Длина, мм	Качество, баллы	Цветовая гамма, баллы	Рисунок, ед	Цена 1м <sup>2</sup> , руб	Цена (Predicted)	Относительная ошибка, %
1	2	3	4	5	6	7	8	9
	Шр	Дл	Кч	Цг	Рис	Цена	Цена (Predicted)	
2	200	330	3	5	1	155	152,07	-1,89
3	250	330	9	5	1	374	374,41	0,11
4	250	330	9	7	1	323	360,37	11,57
5	200	200	7	3	0	374	372,70	-0,35
6	200	330	7	5	0	381	381,58	0,15
7	200	300	7	3	1	145	148,14	2,16
8	200	300	8	5	1	165	167,41	1,46
9	200	300	9	8	1	220	219,94	-0,03
10	250	330	7	7	1	220	298,23	35,56
11	200	300	7	6	1	278	281,22	1,16
12	250	330	7	5	1	190	194,91	2,59
13	200	300	7	5	1	280	244,27	-12,76
14	200	300	5	3	1	145	144,19	-0,56
15	200	250	3	5	1	141	162,16	15,00
16	200	300	9	7	1	220	217,31	-1,22
17	200	250	5	5	1	174	173,19	-0,47
18	200	300	7	7	1	232	221,49	-4,53
19	250	330	9	7	1	360	360,37	0,10
20	200	200	9	9	0	360	360,48	0,13
21	200	250	7	7	1	310	220,46	-28,88
22	200	300	7	7	1	185	221,49	19,72
23	200	300	5	1	0	265	240,94	-9,08
24	200	300	7	7	1	190	221,49	16,57
25	200	300	6	5	1	225	222,89	-0,94
26	200	250	7	1	0	235	235,55	0,23
27	200	250	5	5	1	170	173,19	1,88
28	200	300	5	5	1	130	157,94	21,49
29	200	250	5	6	1	145	157,52	8,64
30	200	250	9	9	1	320	368,51	15,16
31	200	200	9	9	1	365	482,01	32,06
32	200	250	9	9	1	330	368,51	11,67
33	200	250	9	9	1	340	368,51	8,39
34	200	250	8	8	1	310	425,11	37,13
35	200	330	9	9	1	300	299,85	-0,05
36	200	250	3	5	1	170	162,16	-4,61
37	200	250	5	3	1	138	139,70	1,23
38	250	330	8	3	0	360	359,97	-0,01
39	200	250	6	7	1	355	357,69	0,76
40	250	330	6	7	1	255	244,68	-4,05
41	200	200	6	7	1	310	307,10	-0,93

Продолжение табл. 2.8.1.

1	2	3	4	5	6	7	8	9
42	200	330	7	8	1	240	241,88	0,78
43	200	250	5	6	1	170	157,52	-7,34
44	200	250	7	7	1	230	220,46	-4,15
45	200	250	4	5	1	180	164,67	-8,52
46	200	250	7	8	1	265	264,46	-0,20
47	200	250	5	3	0	240	240,24	0,10
48	330	330	5	7	1	320	323,42	1,07
49	250	450	9	7	1	623	656,71	5,41
50	313	400	8	8	1	401	401,80	0,20
51	150	150	8	9	1	420	420,69	0,16
52	250	333	9	8	1	410	469,77	14,58
53	200	200	9	9	1	460	482,01	4,79
54	200	250	7	7	1	175	220,46	25,98
55	200	250	7	7	1	132	220,46	67,02
56	200	250	9	5	1	225	223,84	-0,51
57	198,5	298,5	5	5	1	178	153,26	-13,90
58	198,5	298,5	7	5	1	155	193,47	24,82
59	198	298	9	7	1	178	177,75	-0,14
60	200	250	5	3	1	142	139,70	-1,62
61	250	330	7	6	1	365	365,61	0,17
62	250	330	9	7	1	396	360,37	-9,00
63	200	250	8	6	1	384	468,21	21,93
64	200	250	9	7	1	456	454,00	-0,44
65	200	250	8	6	1	385	468,21	21,61
66	250	450	9	7	1	691	656,71	-4,96
67	200	250	8	6	1	640	468,21	-26,84
68	250	330	8	5	0	720	715,03	-0,69
69	200	300	5	1	0	215	240,94	12,07
70	200	300	7	7	1	270	221,49	-17,97
71	200	300	6	5	1	210	222,89	6,14
72	250	330	7	7	1	365	298,23	-18,29
73	250	330	5	3	1	267	265,65	-0,51
74	250	330	6	1	0	354	353,59	-0,12
75	200	300	5	6	1	185	180,95	-2,19
76	200	250	9	7	1	452	454,00	0,44
77	200	250	8	8	1	485	425,11	-12,35
78	200	250	9	9	1	490	368,51	-24,79
79	250	333	9	3	1	643	643,44	0,07
80	250	333	9	3	0	624	614,96	-1,45
81	250	330	9	4	0	1150	1988,71	72,93
82	250	440	9	5	0	1199	1152,74	-3,86
83	250	330	9	5	0	1094	991,58	-9,36
84	250	333	9	7	0	1003	1001,59	-0,14
85	200	200	9	8	1	1312	1470,16	12,05
86	200	250	8	6	1	525	468,21	-10,82
87	200	250	8	8	1	489	425,11	-13,07
88	200	200	9	9	1	732	482,01	-34,15
89	250	410	9	8	1	1280	1022,04	-20,15
90	250	250	9	8	1	173	173,77	0,45
91	200	300	8	8	1	242	239,76	-0,93
92	200	250	9	7	0	528	528,19	0,04
93	250	330	9	8	1	958	652,62	-31,88
94	200	250	9	8	0	575	575,30	0,05
Среднее значение						374		1,99

### 2.8.3. Методика оценки влияния разницы в себестоимости на оптимальную рыночную цену

В данном исследовании использовали частотный метод анализа. При помощи частотного метода построили гистограмму цен, показывающую зависимость цены от числа предложений. Гистограмма цен была положена в основу построения функции принадлежности.

*Функция принадлежности* определяет в данном случае с какой вероятностью принадлежит та или иная цена к выделенным группам себестоимости.

На основе анализа функции принадлежности выявили 4 характерных интервала цен и определили их точные границы. В итоге получили 4 группы себестоимости, характеристики которых приведены в табл. 2.8.2.

Таблица 2.8.2

#### Характеристики групп себестоимости

№ группы	Лингвистическое название себестоимости	Ценовые пределы	Весовые коэффициенты
1	Низкая	100-300	9
2	Средняя	300-550	7
3	Повышенная	550-800	5
4	Высокая	1000-1400	3

Распределение весовых коэффициентов по группам учитывает возрастание спроса с понижением цены, обусловленной себестоимостью. Определение вероятности принадлежности к группе себестоимости в зависимости от продажной цены представлено на рис. 2.8.1.

Приведём пример определения вероятности принадлежности цены к одной из групп себестоимости. Из рис. 2.8.1. видно, что цена облицовочной плитки, равная 450 руб. за 1м<sup>2</sup> с вероятностью 0,83, относится к средней группе себестоимости. Таким образом, с помощью этого метода можно определять вероятность того, к какой именно группе себестоимости относится интересующая нас цена.




Рис. 2.8.1. Определение вероятности принадлежности к группе себестоимости в зависимости от продажной цены

#### 2.8.4. Анализ оптимальной цены с учётом художественной ценности, дизайна коллекций и разницы себестоимости

На основе данных табл. 2.8.1. было проведено обучение компьютерной нейросети. Обучение прошло успешно, так как погрешность в определении оптимальной цены оказалась незначительной. Далее, с помощью обученной нейросети, рассчитали оптимальную цену на облицовочную плитку в виде композиций для Екатеринбургского завода керамических изделий (ЕЗКИ). Полученные данные позволили сделать следующие выводы.

Было определено, что на оптимальную цену существенно влияют показатели качества дизайна и художественной ценности композиции. Например, когда качество дизайна и художественная ценность композиции оценивается 4 баллами, то соответствующая цена на облицовочную плитку равна 408 руб. за 1 м<sup>2</sup>. Если качество дизайна оценивается 7 баллами, а художественная ценность композиции 6 баллами, то соответствующая цена возрастает до 430 руб. за 1 м<sup>2</sup>. Следовательно, с ростом балла оценки качества производители однозначно увеличивают рыночную оптимальную

цену на облицовочную плитку. При этом учитываются в себестоимости дополнительные затраты на повышение качества.

С помощью компьютерной программы можно сравнить существующую цену на облицовочную плитку с ценой, предсказанной нейросетью для композиций. Рассмотрим художественную композицию “Берёза”, которая производится на ЕЗКИ. Оценка её качества дизайна, художественной ценности достаточно велика (7 и 6 баллов соответственно). Установленная оптимальная цена составляет 347 руб. за 1 м<sup>2</sup>, а существующая же цена облицовочной плитки “Берёза” равна всего 220 руб. за 1 м<sup>2</sup>. Таким образом, наблюдается существенная ценовая разница, которая выражается в недооценке этой художественной композиции. Такое же отличие в ценах имеет художественная композиция “Клён” того же производителя. Можно привести ещё один пример существенной разницы между существующей (248,5 руб. за 1 м<sup>2</sup>) и установленной оптимальной ценой, равной 312 руб. за 1 м<sup>2</sup>, для художественной композиции “Палитра”.

Отсюда следует, что, например, Екатеринбургскому заводу керамических изделий необходимо повысить цену на облицовочную плитку с учётом качества дизайна, художественной ценности композиции, чтобы избежать убытка при продаже.

Для установления конкретного значения оптимальной цены в зависимости от качества дизайна и художественной ценности рекомендуется график цены, изображённый на рис. 2.8.2.




Рис. 2.8.2. Влияние качества дизайна и художественной ценности на оптимальную цену плитки

Улучшение качества плитки на 1 балл дает возможность увеличить начальную цену примерно на 4%. Дальнейшее увеличение качества приводит к уменьшению темпа роста цены, так как изменение качественных показателей с 5 до 6 баллов практически воспринимается потребителем как незначительное. Однако при более существенном улучшении качества (до 7 баллов) покупатель снова готов заплатить почти на 20% дороже, чем за плитку с уровнем качества 4 балла. Влияние цены на величину спроса потребителя отражено на рис. 2.8.3.



Рис. 2.8.3. Влияние цены на спрос

Здесь величина спроса измеряется в условных единицах, численно равных весовым коэффициентам, присвоенным различным группам себестоимости (см. табл. 2.8.2.). Вначале, в диапазоне цен 226-239 руб. за кв.м., картина спроса является инверсной, т.е. спрос растет с увеличением цены. Это объясняется, как было отмечено ранее, повышенным влиянием уровня качества, при котором потребитель согласен переплачивать за плитку лучшего дизайна и лучшей художественной ценности. Однако при дальнейшем увеличении цены, в её диапазоне, где качественные показатели влияют на цену меньше (см. рис. 2.8.2.), спрос начинает уменьшаться и его картина изменения принимает обычный вид. Затем в диапазоне цен от 307 до 484 руб. за кв. м., где уровень качества достигает максимального значения (6 баллов и более) картина спроса снова приобретает инверсный характер.

Таким образом, нейромаркетинг позволяет ориентироваться в реальной картине изменения спроса на рынке и правильно устанавливать необходимую величину оптимальной цены на плитку с учетом художественной ценности композиций и качества дизайна.



Для завода также важно знать такое оптимальное значение цены, при котором достигается максимальное значение объема продаж плитки той или иной композиции. Такая зависимость объема продаж от цены на плитку композиции “Береза” приведена на рис. 2.8.4.




Рис. 2.8.4. Зависимость объёма продаж от цены на плитку композиции “Берёза”

Здесь условный объем продаж рассчитан как произведение величины спроса на цену 1 кв.м. плитки. Для указанной композиции максимальное значение объема продаж имеет место при цене 347 руб. за кв.м. Поэтому именно это значение цены может быть рекомендовано ЕЗКИ в качестве оптимальной. При увеличении цены сверх оптимального значения объем продаж начинает снижаться из-за сокращения спроса по причине необоснованного удорожания. В настоящее время продажная цена на плитку композиции “Береза”, составляющая 220 руб. за кв.м., дает условный объем продаж 1960 руб. В случае продажи плитки по рекомендуемой оптимальной цене 347 руб. за кв.м. объем продаж возрастет до 3091 руб., т.е. на 57%.

## 2.9. Контрольные вопросы и задания

1. Перечислите информационные методы, на которых основана концептуальная модель применения нейросетей.
2. В чём заключается алгоритм решения задачи диагностики с помощью нейросети?
3. Объясните основные принципы управления с помощью нейросети.
4. В чём заключается обучение и адаптация нейроробота?
5. Объясните, на основе чего можно выделить интервалы цен и определить их точные границы в нейромаркетинге.
6. Что учитывает распределение весовых коэффициентов по группам в применении к нейромаркетингу?
7. Перечислите возможные лингвистические названия себестоимости.
8. Дайте определение оптимальной цены.
9. Соберите необходимую информацию и определите нейроцену на сотовые телефоны.
10. Соберите необходимую информацию и определите нейроцену на подержанные автомобили.

## З а к л ю ч е н и е

Изложенный материал по практическому нейрокомпьютингу соответствует общемировой тенденции развития технологии нейросетей. Появление нейророботов–агентов, работающих в реально существующей кибернетической среде Internet (см., например, <http://www.agentware.com>) способствует более полному представлению интересов пользователя во всех отраслях его деятельности. Практически все компьютерные фирмы включены в освоение этого рынка услуг. Достаточно упомянуть Microsoft, тратящую по \$100 млн. в год только на исследования в программном обеспечении. Российский рынок, отставая от зарубежных производителей в аппаратном обеспечении нейрокомпьютинга, в плане научных услуг имеет в настоящее время высокий потенциал, особенно в области перевода созданных ранее разработок и новых результатов научных исследований на нейросетевые технологии. Для полной реализации этого потенциала авторы предлагают использовать в практическом нейрокомпьютинге системный подход, предусматривающий связанные между собой обязательные этапы физической постановки и математической формулировки задачи, алгоритмическое и программное обеспечение решения поставленной задачи, анализ и интерпретацию результатов.

В перспективе развитие основных направлений исследований в области нейрокомпьютинга представляется следующим. Это решение ключевой проблемы улучшения в информационных системах отношения сигнал/шум для производственных процессов с целью повышения эффективности нейросетевого управления. Такое решение должно содержать характеристики ЛПР, влияющие на снижение допустимого порога надежного распознавания сигнала на фоне производственного шума. Это дальнейшая интеграция нейросетей в корпоративные системы с программными технологическими модулями на основе гибридных технологий для улучшения экономичности. Разработка производственных диагностических систем с нейросетями и включение их в контур управления технологией с целью повышения качества производимой продукции и срока службы технологических объектов[28]. Применение нейророботов в локальных системах автоматического регулирования и АСУ ТП с целью достижения высокой надежности и точности управления. Несомненную помощь в предсказании финансовых ситуаций на рынках окажут роботы–агенты, использующие нейромодели инвестора. Такое направление будет наиболее эффективным при оптимальном сочетании технического и фундаментального анализа рыночных процессов. Нейромаркетинг позволит реально объединить рыночные и технологические процессы производства продукции в единую систему с самыми высокими требованиями к конкурентоспособности предприятий.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Гуляев Ю.В. Нейрокомпьютеры в системах обработки сигналов. Кн.9. Коллективная монография / Под ред. Ю.В. Гуляева и А.И. Галушкина. М.: Радиотехника, 2003. 224 с.: ил.
2. Нейронные сети. STATISTICA Neural Networks; пер. с англ. М.: Горячая линия. Телеком, 2000. 182 с.: ил.
3. Гольдштейн С.Л. Высококачественные экспертные системы и базы знаний на основе гибридных технологий: учеб. пособие /С.Л. Гольдштейн, В.Э. Клюкин, Екатеринбург: УГТУ-УПИ, 1995. 75 с.
4. Новицкий П.В. Оценка погрешностей результатов измерений / П.В. Новицкий, И.А. Зограф; 2-е изд., перераб. и доп. Л.: Энергоатомиздат, Ленингр. отд-ние, 1991. 304 с.: ил.
5. Ларичев О.И. Теория и методы принятия решений: учебник / О.И. Ларичев М.: Логос, 2000. 296 с.: ил.
6. Сиберт У.М. Цепи, сигналы, системы / У.М. Сиберт. В 2-х ч; пер с англ. М.: Мир, 1988. 360 с.: сл.
7. Култышева В.А., Щербатский В.Б., Лисиенко В.Г., Познякова М.Н. Использование экспертного управления подачей природного газа и кислорода в доменных печах / В.А. Култышева [и др.] // Изв. Вузов. Черная металлургия. 1995. № 3. С. 7-9.
8. Розенблатт Ф. Принципы нейродинамики / Ф. Розенблатт. М.: Мир, 1966. 270 с.
9. Амосов Н.М. Автоматы и разумное поведение / Н.М. Амосов. Киев: Наук. думка, 1973. 374 с.: ил.
10. Саати Т. Аналитическое планирование. Организация систем / Т. Саати, К. Кернс. М.: Радио и связь, 1991. 310 с.
11. Щербатский В.Б. Информационная оценка компетентности сотрудников в инновационной сфере / В.Б. Щербатский, В.М. Кормышев, М.В. Кириллова // Сб. "Роль инноваций в экономике уральского региона". Материалы Второй региональной конференции. Часть 1. Екатеринбург: Фонд ЦИБ, 2000. 137с.
12. Чертов А.Д. Применение систем искусственного интеллекта в металлургической промышленности / А.Д. Чертов // Металлург. 2003. №7. С. 32-37.
13. Галактика. Комплексная система автоматизации управления предприятием. Проспект корпорации "Галактика". Москва, 2003. 94.
14. Щербатский В.Б. Методы технической диагностики: метод. указания по курсу "Методы технической диагностики"/ В.Б. Щербатский, М.В. Кириллова. Екатеринбург: УГТУ–УПИ, 2000. Ч1. 59 с.
15. Химмельблау Д. Обнаружение и диагностика неполадок в химических и нефтехимических процессах; пер. с англ. / Д. Химмельблау. Л.: Химия, 1983. 352 с., ил.

16. Кириллова М.В. Нейронная диагностика процесса обжига электрокерамики / М.В. Кириллова, В.М. Кормышев, В.Б. Щербатский. // Радиоэлектроника, электротехника энергетика: сб. докладов шестой международной научнотехнической конференции МЭИ. Москва, 2000, Т1. с. 315.
17. Сысоев Н.П. [и др.] Опыт работы доменных печей ЧерМК с пониженной интенсивностью / Н.П. Сысоев [и др.] // Сталь. 1993. № 5. С. 10-12.
18. Кириенкова М.А. [и др.] Диагностика распределения материалов и газов в доменной печи / М.А. Кириенкова [и др.] // Известия вузов. Черная металлургия. 2001. № 1. С.11-15.
19. Марселлус Д. Программирование экспертных систем на Турбо-Прологе; пер. с англ. предисл. С.В. Трубицына /Д. Марселлус. М.: Финансы и статистика, 1994. 256 с.
20. Власов – Власюк О.Б. Экспериментальные методы в автоматике / О.Б. Власов– Власюк. М.: Машиностроение, 1969. 412 с.
21. В. Saxen and Н. Saxen. NNDT- A Neural Network Development Tool. User's Guide / В. Saxen and Н. Saxen. Department of Chemical Engineering Ebo Akademi University, 1995 . 19 с.
22. <http://www.stockbroker.ru/stockbroker/researchq.asp>
23. Горяшко А.А. Фондовый рынок: рациональные мотивы нерационального поведения / А.А. Горяшко // Сб. трудов Института точной механики и вычислительной техники им. С.А. Лебедева РАН, М.: 2002. 23 с.
24. Ротач В.Я. Теория автоматического управления теплоэнергетическими процессами: учебник для вузов / В.Я. Ротач. М.: Энергоатомиздат, 1985. 296 с., ил.
25. Сорос Дж. Кризис мирового капитализма. Открытое общество в опасности; пер. с англ / Дж. Сорос. М.: ИНФРА-М, 1999. XXVI, 262 с.
25. Попова Т.И. Маркетинг. Теория, ситуации, тесты: учеб.– метод. пособие / Т.И. Попова. М.: "Книга сервис", 2003. 112с.
26. Гущина О.В. Применение нейромаркетинга для определения оптимальной цены на продукцию Екатеринбургского завода керамических изделий / О.В. Гущина, В.Б. Щербатский, Ю.Н. Овчинников// Вестник: труды третьей международной научно-практической конференции РУО Академии инженерных наук им. А.М.Прохорова. Екатеринбург, УГТУ-УПИ, 2004. Ч.2, №15(45). С. 47–49.
27. Щербатский В.Б. Нейроробот “Партнёр мастера” для управления комбинированным дутьём доменных печей / В.Б. Щербатский, Ю.Н. Овчинников, А.С. Карцев // Вестник: труды третьей международной научно-практической конференции РУО Академии инженерных наук им. А.М. Прохорова. Екатеринбург, УГТУ-УПИ, 2004. Ч.2, №15(45). С. 8–13.

*Учебное пособие*

Сергей Людвигович Гольдштейн  
Виктор Борисович Щербатский  
Ольга Владимировна Гущина

ПРАКТИЧЕСКИЙ НЕЙРОКОМПЬЮТИНГ

Редактор *Н.В. Рощина*  
Компьютерный набор *авторов*

ИД № 06263 от 12.11.2001 г.

---

Подписано в печать		Формат 60 × 84 1/16
Бумага писчая	Печать плоская	Усл. печ. л. 3,95
Уч.–изд. п.	Тираж	Заказ
Цена “С”		

---

Редакционно–издательский отдел ГОУ ВПО УГТУ–УПИ  
620002, Екатеринбург, ул. Мира, 19.  
Ризография НИЧ ГОУ ВПО УГТУ–УПИ  
620002, Екатеринбург, ул. Мира, 19.



