

Родионов Павел Евгеньевич

**МЕТОДИКА ИЗВЛЕЧЕНИЯ ЗНАНИЙ В ЗАДАЧАХ АНАЛИЗА РЯДОВ
ДИНАМИКИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ**

Специальность 05.13.17 – Теоретические основы информатики

**Автореферат диссертации на соискание ученой степени
кандидата технических наук**

Москва - 2003

Работа выполнена в Московском государственном техническом университете им.Н.Э.Баумана.

Научный руководитель:

кандидат технических наук,
доцент Филиппович Ю.Н.

Официальные оппоненты:

доктор технических наук,
профессор Черевков К.В.
доктор технических наук,
старший научный сотрудник
Фоминых И.Б.

1618029		
Родионов П.Е.		
Методика извлечения знаний в задачах анализа рядов динамики с использованием нейрон...		
2003		0-00

ОАО "НПК НИИ ДАР"

29 » мач 2003 года в 14³⁰ часов

Московского


мана по адресу:

1618029

ВОЗВРАТИТЕ КНИГУ НЕ ПОЗЖЕ
обозначенного здесь срока

ке МГТУ им.

Р.Иванов



1. Общая характеристика работы

1.1 Актуальность темы


Получение практически полезных и доступных интерпретации знаний необходимо для принятия решений в различных сферах человеческой деятельности. Подобные задачи актуальны в областях, где присутствуют большие информационные массивы неоднородных, меняющихся во времени данных высокой размерности.

Проблема извлечения знаний и выявления скрытых закономерностей в массивах данных подразделяется на пять различных задач: нахождение ассоциаций, нахождение последовательностей, классификацию, кластеризацию и прогнозирование. Ввиду широты проблематики, связанной с извлечением знаний из массивов данных, область исследований была сужена и в диссертационной работе рассматривается задача анализа рядов динамики с целью прогнозирования, то есть предсказания поведения объекта в будущем на основе ретроспективной информации, хранящейся в виде временных рядов.

Рассматриваемая задача актуальна в различных областях. В частности, в представляемой диссертационной работе приведены результаты решения задачи уточнения траекторного прогноза движения искусственного спутника земли (ИСЗ), а также задачи оценки влияния случайных возмущений на параметры авиационного насоса. Характерной предметной областью, в которой необходимо решение задачи нахождения прогноза с учетом выявляемых закономерностей в массивах данных, являются финансовые рынки. В настоящее время существует несколько сот организаций-участников финансового рынка, результаты деятельности каждой из которых напрямую зависят от успешности решения подобной задачи. При этом данные организации оперируют значительными суммами. Например, совокупный оборот только московской межбанковской валютной биржи (ММВБ) в 2001г. составил 107 млрд. долларов США. Таким образом, решение задачи анализа рядов динамики с целью нахождения прогноза необходимо в различных сферах деятельности человека. При этом для определенного класса задач (выделенного в рамках диссертационной работы) применимость традиционно используемых методов математической статистики и технического анализа ограничена. Таким образом, создание методики решения данного класса задач является актуальной научно-технической проблемой.

1.2 Цель работы и задачи исследования

Целью настоящей диссертационной работы является разработка методики извлечения знаний из совокупности эмпирических данных и учета неформализуемых информационных зависимостей для предсказания будущего состояния нестационарного временного ряда с помощью аппарата нейронных сетей, позволяющей решать выделенный класс задач



прогнозирования с обеспечением практически значимой устойчивой точности выдаваемых нейронной сетью прогнозов.

Основными задачами исследования являются:

- выделение класса задач, для которого ограничена применимость существующих методов прогнозирования
- предложение методики решения данного класса задач, а в рамках методики разработка комплекса приемов и методов по повышению ее эффективности
- выработка практических рекомендаций по использованию разработанной методики
- оценка эффективности предложенной методики в ходе экспериментов

1.3 Методы исследования

Результаты проведенных и представленных в диссертации исследований получены с использованием теории математической статистики, теории нейронных сетей, комбинаторики, методов общей алгебры, теории дифференциального и матричного счисления, методов оптимизации.

1.4 Научная новизна

Научную новизну работы составляют:

1. Разработанная методика прогнозирования, основанная на учете взаимосвязей между прогнозируемой величиной и влияющими на нее факторами, и использующая массив эмпирических данных за предшествующий период. Методика позволяет находить прогноз на основе совместной обработки нескольких нестационарных временных рядов.
2. Разработанный новый способ нормировки данных, представляющий собой комбинацию линейных и нелинейных (с изменяемым видом нелинейности) преобразований над данными.
3. Разработанные функции ошибки нейронов и суммарной ошибки нейронной сети, обеспечивающие повышение точности предсказания знака изменения значения прогнозируемой величины в будущий момент времени.
4. Предложен новый алгоритм обучения нейронной сети, использующий разработанные функции ошибки. В качестве его теоретического обоснования доказан ряд теорем.

1.5 Практическая ценность работы

Практическая значимость работы состоит в разработке формальной методики, обеспечивающей возможность ее использования широким кругом организаций. Приведены конкретные практические рекомендации по использованию методики и предложенных в ее рамках приемов в различных областях деятельности человека. Созданные в рамках диссертационной работы программные средства могут быть использованы для автоматизации

деятельности организаций, сталкивающихся с необходимостью учета неформализуемых зависимостей при прогнозировании нестационарных временных рядов.

1.6 Реализация и внедрение результатов работы

Разработанная методика используется как средство поддержки принятия решений в инвестиционной компании ОАО «Ай-Си-Эм Финанс». Созданные в рамках диссертационной работы программные средства включены в состав АСУ предприятием ЗАО «Страховое общество ВАВИЛОН». В обеих организациях внедрение принесло положительный результат, что подтверждено соответствующими документами.

1.7 Апробация работы

Основные положения диссертационной работы докладывались и получили одобрение на заседаниях кафедры «Системы обработки информации и управления» МГТУ им.Баумана, на заседаниях комиссий по аттестации аспирантов в 2000-2002гг. , а также на 42 научно-технической конференции МГУП.

1.8 Работы по теме диссертации

Автор имеет четыре работы по теме диссертации, а также три подготовленных к опубликованию.

1.9 Структура и объем работы

Диссертационная работа состоит из введения, четырех глав, заключения, списка использованной литературы и приложений. Общий объем основного текста диссертации 138 страниц.

2. Основное содержание работы

Во введении обосновывается актуальность работы, определяется класс рассматриваемых задач. Ставятся цели и задачи исследования, приводятся основные положения работы.

Диссертационная работа посвящена вопросу разработки методики извлечения знаний из эмпирических данных, представленных нестационарными временными рядами, с использованием теории нейронных сетей. Цель состоит в выявлении скрытых, нетривиальных и неформализуемых закономерностей в наборах данных. Как указывалось ранее, выявление закономерностей необходимо при решении нескольких различных типов задач (рис. 1). В представляемой диссертационной работе рассматривалась задача прогнозирования, имеющая следующие особенности:

-на прогнозируемую величину влияют нескольких различных факторов (динамика изменения значений которых также представлена временными

рядами). Нахождение и аналитическое описание зависимостей, характеризующих эти взаимосвязи, затруднено.

-рассматриваемые временные ряды являются нелинейными и нестационарными

-вид нелинейности временного ряда априорно не известен и не описан аналитически

-в результате решения задачи требуется нахождение не сглаженного краткосрочного прогноза.



Рис.1. Типы задач

Вышеприведенные особенности определяют класс рассматриваемых в диссертационной работе задач, предполагающих осуществление для их решения совместной обработки нескольких временных рядов.

Для оценки применимости различных методов к решению задачи прогнозирования с учетом ее вышеперечисленных особенностей, в главе 1 производится обзор методов математической статистики и технического анализа, традиционно использующихся для прогнозирования на финансовых рынках. Среди статистических методов рассматриваются экспоненциальное сглаживание, АРПСС (авторегрессионное проинтегрированное скользящее среднее), множественная регрессия, спектральный анализ и метод сезонной декомпозиции. В ходе анализа этих методов показывается, что специфика задачи ограничивает возможности применения данных методов.

Также рассматриваются различные методы технического анализа, де-факто использующиеся при прогнозировании в финансовой сфере. Среди положительных черт технического анализа отмечаются свойственные ему гибкость и адаптационные способности. Также сильной стороной технического анализа является возможность его применения на любом

отрезке времени. Среди недостатков - субъективизм эксперта (особенно в графическом анализе), обилие ложных сигналов, противоречивость различных индикаторов. Другим отмеченным принципиальным недостатком является то, что анализ основывается лишь на прогнозируемом ряде, не используя в явной форме информацию по другим факторам, влияющим на прогнозируемую величину. Таким образом, возможности аппарата технического анализа заведомо сужены по сравнению с примененным в данной работе подходе, заключающемся в использовании для прогноза нескольких различных факторов с учетом их взаимосвязей.

В первой главе также приводятся сведения о нейронных сетях. К основному недостатку нейронных сетей отнесено отсутствие формализованных методик построения нейросетевой модели, а как следствие высокая сложности ее построения. Поэтому большую практическую ценность приобретает разработка формальной методики настройки и обучения сети и выработка конкретных рекомендаций, которые позволят более успешно применять аппарат нейронных к решению выделенного класса задач.

При этом математическая постановка решаемой задачи выглядит следующим образом:

Y - объект прогноза (Рис. 2), представленный временным рядом своих значений в предшествующие моменты времени $Y_{t-k}, Y_{t-k+1}, \dots, Y_t$, где t - текущий момент времени, k - глубина ретроспективной выборки. На




Рис. 2. Иллюстрация к постановке задачи

поведение Y влияет совокупность факторов (характеристик): $V_1, \dots, V_n$, где n -

количество факторов. Каждая i -ая характеристика ($i=1..n$) также представлена совокупностью своих предыдущих значений $V_{t-k}^{(i)}, V_{t-k+1}^{(i)}, \dots, V_t^{(i)}$. Исходя из физического смысла задачи Y принадлежит V , т.к. предыдущие значения Y влияют на его будущее значение и, следовательно, должны входить в V . В общем случае глубина ретроспективной выборки для различных $V^{(i)}$ может быть различной. Требуется найти значение Y в будущий момент времени на основе известных предыдущих значений V . В зависимости от физического смысла задачи может одновременно прогнозироваться несколько величин, то есть значение Y в каждый момент времени может быть вектором.

Глава 2 диссертационной работы посвящена нейросетевому моделированию процессов обработки экспериментальных данных. Осуществляется классификация существующих парадигм нейронных сетей по структуре (Рис.3), по особенностям модели нейронной сети, по видам обучения.



Рис. 3. Классификация нейронных сетей

При классификации по особенностям модели нейронной сети наиболее важным является разделение всего множества моделей на бинарные и аналоговые (то есть с дискретными и непрерывными сигналами). При классификации по методам обучения выделяются самообучающиеся сети и сети, обучающиеся с учителем (супервизором).

Производится анализ применимости различных архитектур нейронных сетей к решению различных задач (Таблица 1):

Результатом данного анализа является выделение двух типов сетей, в наибольшей степени подходящих для решения задачи прогнозирования – сети радиального базиса и многослойный перцептрон (MLP). Для обеих архитектур подробно рассматриваются строение и принцип функционирования, а также исследуются достоинства и недостатки.

В результате проведенного сравнительного анализа делается выбор в пользу архитектуры типа «многослойный перцептрон», которая и использовалась в рамках методики. Данная архитектура в большей степени отвечает специфике рассматриваемой задачи, так как обладает способностью экстраполировать данные, более компактна за счет эффективного использование всех нейронов сети, зачастую требует меньшего числа обучающих примеров и имеет удовлетворительную для решения рассматриваемой задачи скорость обучения.

Таблица 1.

	Ассоциативная память	Сжатие информации	Прогнозирование	Оптимизация	Классификация	Кластеризация
Сеть Хопфилда	+			+		
Сеть встречного распространения	+	+				
Сеть радиального базиса			+		+	
Карта Кохонена				+	+	+
Многослойный перцептрон (MLP)	+	+	+		+	
Двунаправленная ассоциативная память	+					
Сеть Хэмминга	+				+	
Вероятностная Сеть PNN					+	
Сеть адаптивного резонанса ART2					+	+

Также во второй главе также исследуется необходимость проведения предварительной нормировки данных для различных типов нейросетей и алгоритмов обучения, описываются способы проведения нормировки (линейная нормировка и нормировка на основе статистических характеристик ряда). Линейная нормировка, выполняемая по формулам:

$$S_i = \frac{x_i - \text{midrange}}{\frac{\text{range}}{2}}, \text{ где } S_i - \text{нормированное значение,}$$

$$\text{range} = \max_i x_i - \min_i x_i; \quad \text{midrange} = \frac{\max_i x_i + \min_i x_i}{2},$$

сводит все значения к диапазону $[-1;1]$.

Нормировка на основе статистических характеристик ряда по формулам:

$$S_i = \frac{x_i - \tilde{m}_x}{\tilde{D}_x}, \text{ где}$$

$$\tilde{m}_x = \frac{1}{N} \cdot \sum_{i=1}^N x_i - \text{математическое ожидание,}$$

$$\tilde{D}_x = \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - \tilde{m}_x)^2 - \text{дисперсия;}$$

приводит значения к нулевому математическому ожиданию и единичной дисперсии.

Для применяемой в рамках методики архитектуры MLP показывается необходимость проведения нормировки как для входных, так и для выходных данных. Так, нормировка входных данных позволяет избежать при обучении выхода нейронов на уровень насыщения, а также позволяет нейронной сети работать со значениями входов, диапазоны представления которых сильно различаются. Нормировка выходных данных выполняет аналогичные функции, а также позволяет привести значения выходов к области определения функции активации, что необходимо для успешного обучения нейронной сети.

В главе 3 диссертационной работы описывается разработанная методика краткосрочного прогнозирования и реализующие ее программные средства. Представляемая методика состоит из четырех этапов и основана на учете скрытых зависимостей между различными факторами в массиве эмпирической информации. При этом методика позволяет решать задачу прогнозирования на основе совместной обработки нескольких влияющих друг на друга временных рядов, не накладывая никаких ограничений на их характер.

На первом этапе методики на основе экспертной оценки определяется избыточный набор факторов, влияющих на объект прогноза, осуществляется импорт данных из торговой системы, а также проводится предварительная обработка данных. На втором этапе производится определение параметров модели, а именно: нахождение глубины ретроспективной выборки, определение состава входных факторов и структуры сети (число слоев и нейронов), задание параметров обучения. На третьем этапе происходит формирование обучающих примеров, обучение сети и оценка качества модели. Четвертый этап представляет собой получение реального прогноза на данных, ранее неизвестных сети, а также проведение процедур, обратных процедурам предварительной подготовки данных. Ниже будут рассмотрены ключевые моменты методики.

Для предварительной подготовки данных предложено применение комбинации нормировки на основе статистических характеристик ряда и

нелинейной нормировки с использованием функции активации, выполняющейся по формулам:

$$S_i = f\left(\frac{x_i - \bar{m}_x}{\bar{D}_x}\right), \quad f(a) = \frac{2}{1 + e^{-k \cdot a}} - 1, \text{ где}$$

$f(a)$ –используемая при обучении функция активации
(в данном примере – биполярная сигмоида, , область определения [-1;1])

Новизна данного подхода заключается в изменяемом виде нормирующей функции $f(a)$, что позволяет повысить эффективность нормировки путем лучшего приближения распределения данных к равномерному (это позволяет повысить энтропию данных, а в конечном итоге – увеличить информативность обучающих примеров). Для возможности изменения вида функции активации в ее состав введен специальный коэффициент. На рис. 4 показаны гистограммы, характеризующие распределение значений ряда котировок ОГВВЗ в диапазоне [-1;1] после нормировки различными способами:



Рис. 4. Результаты различных способов нормировки

Действительно, приведенные гистограммы свидетельствуют о том, что после нелинейной нормировки с изменяемым видом нелинейности данные наиболее равномерно заполняют отведенный им диапазон.

Для определения глубины ретроспективной выборки по каждому фактору, т.е. количества предшествующих значений, которое будет использоваться при построении прогноза, выполняется расчет и анализ графинов автокорреляционных функций. В работе выработан ряд практических рекомендаций по выбору глубины ретроспективной выборки на основе анализа данных графиков.

Для корректировки состава входных факторов предлагается использовать следующую процедуру: к уже существующей модели добавляется следующий фактор из числа неиспользованных, дающий

наибольшее улучшение предсказательной способности модели. Первоначальная модель строится только на основе прогнозируемого ряда. Добавление дополнительных факторов прекращается, если оно перестанет улучшать точность модели. Возможно также продолжать добавление до конца, пока не будут использованы все факторы, а затем выбрать наилучшую комбинацию факторов из полученных вариантов.

В работе использовалась сеть с входным, одним скрытым и выходным уровнями. Количество нейронов входного уровня определяется числом используемых входных факторов и глубиной ретроспективной выборки по формуле

$$n^{(I)} = \sum_p P \cdot k_p, \text{ где } ?$$

P -число входных факторов, k_p - глубина ретроспективной выборки по p -ому фактору.

На выходном уровне находился один нейрон, выдающий прогноз, а количество нейронов скрытого уровня варьировалось в диапазоне от $N/2$ до $3N$, где N – количество входных нейронов. В качестве функции активации применялась биполярная сигмоида, к достоинствам которой можно отнести несмещенность относительно нуля оси ординат.

В рамках методики предложена **новая**, разработанная с учетом специфики задачи **функция ошибки**, характеризующая расхождение между реально полученным и требуемым выходом нейросети. Идея ее применения заключается в том, что при прогнозировании экономических временных рядов важнее правильное определение знака будущего изменения, нежели его абсолютного значения. Ведь если знак определен неверно, результатом является неправильное решение (например, покупка ценных бумаг вместо их продажи), что ведет к убыткам. В то же время, если знак определен верно, решение принимается верное и неточность предсказания абсолютной величины изменения котировки не столь критична. Учитывая данную специфику предметной области, традиционно применяющееся в качестве функции ошибки среднеквадратическое отклонение не является лучшим выбором.


Разработанная функции ошибки γ в общем случае (для j -го нейрона выходного слоя) имеет вид:

$$\gamma_j = \frac{1}{1 + e^{-c[\text{sign}_j \cdot (y_j - t_j) - d]}} - h, \text{ где}$$

c, d, h – константы,

t_j – желаемый, y_j – реальный выход нейрона j

$\text{sign}_j \cdot (y_j - t_j) > 0$, если знаки y_j и t_j не совпадают и < 0 , если совпадают



Константы: $c=2.5$, $h=0.2$; $d=0.5545$

Рис. 5. Вид функции ошибки

Как видно из представленного на рис. 5 графика, при правильно предсказанном знаке будущего изменения функция ошибки быстро выходит на уровень насыщения, при этом значение ошибки невелико по модулю (отрицательная полуось). Если знак изменения спрогнозирован неверно, функция ошибки резко возрастает даже при незначительном по модулю расхождении желаемого и реального выходов сети. Параметрами, задающими вид функции ошибки, являются три константы: c, d, h . Взаимная зависимость данных констант для обеспечения равенства функции ошибки нулю при совпадении требуемого и реального выходов выражается формулой:

$$d = \frac{\ln\left(\frac{1-h}{h}\right)}{c}.$$

В рамках методики была также используется **разработанная функция суммарной ошибки**, представляющая собой ошибку не отдельного нейрона, а всей сети. Суммарная ошибка i -го примера в общем случае складывается из ошибок каждого нейрона выходного слоя (при единственном выходном нейроне берется его ошибка), деленных на константу c , входящую в выражение для функции ошибки нейрона γ :

$$E = \frac{1}{c} \cdot \sum_j \gamma_j.$$

В качестве критерия останова предлагается применять пороговое значение разработанной функции суммарной ошибки: $\sum_i E_i < Q$, где E_i - суммарная ошибка i -го примера, Q - порог.

Учитывая, что выражения функции ошибки нейрона, суммарной ошибки и формулы функционирования алгоритма обучения взаимосвязаны, разработка нестандартной функции ошибки нейрона повлекло за собой применение особой функции суммарной ошибки, а также разработку нового алгоритма обучения нейронной сети. Разработанный алгоритм основан на базовых принципах алгоритма обратного распространения ошибки. В качестве теоретического обоснования примененного в составе алгоритма дельта-правила (правила корректировки весов и смещений) в диссертационной работе были доказаны три теоремы.

Теорема 1.

Ошибка предпоследнего слоя i может быть выражена через ошибку последующего (выходного) слоя j с помощью формулы:

$$\gamma_i = \sum_j \text{sign} \cdot (1 - \gamma_j) \cdot \gamma_j \cdot F'(s_j) \cdot \omega_{ij}$$

Теорема 2.

Производные ошибки по весовым коэффициентам и порогам нейронов для выходного слоя j и предшествующего слоя i определяются следующим образом:

$$\frac{\partial E}{\partial \omega_{ij}} = \text{sign} \cdot (1 - \gamma_j) \cdot \gamma_j \cdot F'(s_j) \cdot y_i$$

$$\frac{\partial E}{\partial b_j} = -\text{sign} \cdot (1 - \gamma_j) \cdot \gamma_j \cdot F'(s_j)$$

Теорема 3.

Производные ошибки по весовым коэффициентам и порогам нейронов для любых двух слоев (исключая выходной) i и k (k предшествует i) определяются следующим образом:

$$\frac{\partial E}{\partial \omega_{ki}} = \gamma_i \cdot F'(s_i) \cdot y_k; \quad \frac{\partial E}{\partial b_i} = -\gamma_i \cdot F'(s_i)$$

Использованная в выражениях обобщенного дельта – правила производная функции активации $F'(s)$ для используемой биполярной сигмоиды определяется следующим образом: выходное значение j -го нейрона определяется по формуле $y_j = \frac{2}{1 + e^{-s_j}} - 1$, тогда

$$F'(s_j) = \frac{\partial E}{\partial s_j} = \frac{1}{2} \cdot (1 - y_j^2).$$

Блок-схема разработанного алгоритма представлена на рис. 6.




Рис.6. Блок-схема разработанного алгоритма

В главе 4 диссертационной работы описаны эксперименты, проведенные на реальных данных по трем различным практическим задачам.

Первая задача использовалась для оценки эффективности как отдельных приемов, предложенных в рамках разработанной методики, так и методики целиком. Для этого было проведено пять экспериментов. В качестве предметной области в для первой задачи использовалась финансовая сфера, а именно прогнозирование котировок пятого транша облигаций государственного внутреннего валютного займа (ОГВВЗ). Подобный выбор предметной области и объекта прогноза объясняется доступностью и полнотой необходимой первичной информации, интересной для проведения эксперимента динамикой изменения котировок, а также полным соответствием данной задачи выделенному в диссертационной работе классу задач, для которого и была разработана методика.

Проведенные эксперименты подтвердили:

- а) обоснованность предложенной процедуры перехода от анализа абсолютных значений элементов временных рядов к анализу их относительных изменений
- б) эффективность процедуры определения глубины ретроспективной выборки, обеспечивающей выбор значений, близких к наилучшим при существенном снижении трудоемкости
- в) эффективность предложенного в рамках методики способа нормировки, показавшего среди четырех различных способов лучший результат и позволившего снизить ошибку обучения сети в 3-4 раза относительно данных, нормировка которых не проводилась
- г) эффективность методики в целом, позволившей обеспечить точность прогноза на уровне 73-75% в наиболее неблагоприятных условиях.

В качестве второй задачи было рассмотрено построение нейросетевой модели, выполняющей прогноз ошибки определения координат ИСЗ с помощью аналитической модели на основе анализа ретроспективной эмпирической информации. Целью эксперимента является демонстрация возможности учета влияния случайных возмущающих факторов, формальный аналитический учет которых затруднен или невозможен (в качестве примера можно привести изменение характеристик атмосферы из-за активности Солнца). В результате эксперимента знак будущего изменения величины ошибки был правильно предсказан нейронной сетью в 19 случаях из 21 (т.е. в 90% случаях). Полученные результаты обеспечивают возможность уточнения аналитического прогноза путем вычитания величины ошибки, полученной с помощью нейронной сети. При этом данная операция в 90% случаев не приводит к ухудшению показателей аналитической модели, так как нейронная сеть правильно предсказала знак будущего изменения и при проведении корректировки итоговое значение ошибки уменьшается.

В качестве третьей была рассмотрена задача оценки влияния случайных возмущений на характеристики авиационного насоса. Суть задачи заключается в определении причины выхода измеряемой в процессе

испытаний характеристики агрегата из допустимого диапазона (несоответствие агрегата техническим условиям, либо влияние случайных возмущений). Целью эксперимента была демонстрация возможности улучшения точностных показателей, получаемых с помощью разработанной методики, путем использования комитетов нейросетей (то есть нескольких сетей, имеющих идентичное строение, но различные начальные значения весовых коэффициентов). В ходе данного эксперимента применение комитета нейросетей позволило на 25% улучшить первоначально полученный результат.

3. Основные выводы и результаты работы:

1. Выполнен анализ существующих методов прогнозирования временных рядов. Проведен анализ достоинств и недостатков каждого метода, оценена область его применимости при решении задач прогнозирования.

2. Выявлен класс задач, при решении которых нейронные сети имеют преимущество перед традиционными методами математической статистики и технического анализа. Данные задачи характеризуются следующими свойствами:

- нестационарность и нелинейность прогнозируемого процесса

- необходимость нахождения несглаженных прогнозов

- необходимость совместного использования для нахождения прогноза нескольких временных рядов, содержащих значения факторов, влияющих на объект прогноза.

- затрудненная формализация зависимостей между значением прогнозируемой величины и факторами, на нее влияющими.

3. Предложена формальная постановка задачи прогнозирования, предполагающая нахождение одношагового прогноза на основе обработки массива эмпирических данных с использованием аппарата нейронных сетей. На основе выполненной классификации нейросетевых архитектур проведен сравнительный анализ применимости различных парадигм нейронных сетей к решению рассматриваемого класса задач.

4. Разработана состоящая из четырех этапов методика решения поставленной задачи. В рамках методики предложен новый способ нелинейной нормировки данных, заключающийся в последовательном выполнении над ними линейных, а затем нелинейных преобразований с изменяемым видом нелинейности, предложена процедура подбора субоптимального состава входных факторов, а также способ определения глубины ретроспективной выборки на основе средств корреляционного анализа.

5. В рамках методики предложена новая функция ошибки нейронов при обучении сети, обеспечивающая более надежное предсказание направления будущего изменения прогнозируемой величины, а также реализующий ее новый алгоритм обучения сети. В качестве его теоретического обоснования

доказан ряд теорем. Разработана функция суммарной ошибки обучения, предложен основанный на данной функции критерий останова обучения. Разработан пакет программ, включающий программные средства моделирования работы нейронной сети и ее обучения по новому алгоритму.

6. Произведен ряд экспериментов, в ходе которых подтверждена обоснованность применения приемов и процедур, использующихся в рамках методики, а также эффективность методики в целом. Так, достигнутая точность прогноза на реальных данных составила для различных задач 73-90%, что является практически значимым результатом.

4. Работы по теме диссертации

1. Родионов П.Е. Решение задач финансового прогнозирования с использованием нейронных сетей // Современные технологии в задачах управления, автоматики и обработки информации: Сборник трудов международного научно-технического семинара. – М., 1997. – С.248-250

2. Родионов П.Е. Решение проблем поиска информации путем использования самообучающихся адаптирующихся систем на базе нейронных сетей // Интеллектуальные технологии и системы. –(М.), 2001. – Вып.3.- С.60-61

3. Родионов П.Е. Краткосрочное прогнозирование котировок ОГВВЗ с использованием аппарата нейронных сетей // Интеллектуальные технологии и системы.–(М.), 1998. – Вып.1. - С.231-245

4. Родионов П.Е. Классификация существующих парадигм нейронных сетей // Материалы 42 научно-технической конференции преподавателей, сотрудников и аспирантов МГУП. -М., 2002. – С.29-30

Принято к исполнению 24/03/2003
Исполнено 25/03/2003

Заказ № 245
Тираж: 100 экз.

ООО «НАКРА ПРИНТ» ИНН 7727185283
Москва, Балаклавский пр-т, 20-2-93
(095) 318-40-68
www.autoreferat.ru