

0- 786277

На правах рукописи

АВДЕЕВ АЛЕКСАНДР СЕРГЕЕВИЧ

**РАЗРАБОТКА АДАПТИВНЫХ МОДЕЛЕЙ И ПРОГРАММНОГО
КОМПЛЕКСА ПРОГНОЗИРОВАНИЯ ЭКОНОМИЧЕСКИХ
ВРЕМЕННЫХ РЯДОВ**

05.13.18 – Математическое моделирование, численные методы
и комплексы программ

АВТОРЕФЕРАТ
диссертации на соискание ученой степени
кандидата технических наук

Барнаул – 2010

Работа выполнена в ГОУ ВПО «Алтайский государственный технический университет им. И.И. Ползунова»

**Научный руководитель – Доктор технических наук,
профессор Пятковский Олег Иванович**

**Официальные оппоненты – Доктор физико-математических наук,
профессор Алгазин Геннадий Иванович**

**Кандидат технических наук
Врагова Елена Владимировна**

**Ведущая организация – ФГАОУ ВПО «Сибирский Федераль-
ный Университет» (г. Красноярск)**

Защита диссертации состоится 22 октября 2010 года в 10⁰⁰ часов на заседании диссертационного совета Д 212.005.04 при ГОУ ВПО «Алтайский государственный университет» по адресу: 656049, Барнаул, пр. Ленина, 61.

С диссертацией можно ознакомиться в библиотеке ГОУ ВПО «Алтайского государственного университета».

Автореферат разослан 21 сентября 2010 г.

Ученый секретарь
диссертационного совета,
доктор физико-математических
наук, профессор



С.А. Безносюк

НАУЧНАЯ БИБЛИОТЕКА КГУ



0000582408

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы. Эффективное управление предприятием невозможно без решения задач прогнозирования важнейших технико-экономических показателей. Получение правильного прогноза позволяет адекватно оценивать ситуацию и быть готовым отреагировать на её изменение.

Решению задачи прогнозирования на основе моделей временных рядов посвящено большое количество исследований. Существуют успешные решения с использованием вероятностных методов, нейросетевого моделирования, субъективных знаний экспертов. Исследованиям в данной области посвящены работы Бокса Дж., Дженкинса Г., Боровикова В.П., Ивченко Г.И., Лукашина Ю.П., Оссовского С., Комарцовой Л.Г., Колмогорова А. Н., Максимова А.В. и др.

Временные ряды, порожденные экономическими процессами, как правило, являются нестационарными, т.е. их характеристики меняются во времени, изменяются взаимосвязи и взаимозависимости объекта прогнозирования. Более того, меняется во времени состав, структура и направление взаимодействия элементов, составляющих объект прогнозирования. Таким образом, для нестационарных временных рядов классические модели прогнозирования обладают рядом недостатков, или являются полностью непригодными. При изменении характеристик временного ряда возникает необходимость в адаптивном прогнозе. В связи с этим актуальной является разработка новых методов и алгоритмов и программно-математических инструментариев на их основе, делающих возможным получение достоверных прогнозных данных, сокращение времени обработки данных.

В связи с широким распространением программных средств поддержки принятия решений, особую важность представляет разработка моделей и алгоритмов автоматизированного прогнозирования для использования результатов прогноза в аналитических программных комплексах. Автоматизированное прогнозирование с использованием вычислительной техники предполагает функционирование прогнозирующих моделей и алгоритмов с минимальным участием человека, автоматический выбор структуры модели и ее параметров для прогнозирования конкретных показателей, численно выражаемых с помощью временного ряда.

В настоящее время компьютерные технологии вышли на тот уровень, когда появилась реальная возможность говорить о разработке интеллектуальных информационных систем прогнозирования временных рядов, использующих концепцию нейросетевого моделирования. Теория искусственных нейронных сетей была создана и развита такими учеными, как Розенблатт Ф., Минский М., Гроссберг С., Кохонен Т. Вопросам теории и практического использования искусственных нейронных сетей посвящены работы таких

ученых России, как Горбань А.Н., Галушкин А.И., Шумский С.А., Ежов А.А., Миркес Е.М., Дунин-Барковский В.Л., Россиев Д.А.

Однако следует отметить, что не все задачи могут быть решены при помощи нейросетевых методов. Часть задач в информационных системах проще решить при помощи формальных методик. Другие – трудноформализуемые, но имеющие логическую прозрачность – при помощи традиционных экспертных систем. Поэтому наиболее эффективных результатов можно достичь при использовании гибридных экспертных систем, что было показано в работах Силича В.А., Пятковского О.И. При этом в структуре такой системы могут входить блоки, реализующие математические методы, экспертные системы, основанные на правилах продукций, фреймах, прецедентах и других, а также нейросетевые элементы.

Цель диссертационной работы состоит в разработке комплекса математических моделей для адаптивной системы прогнозирования временных рядов на основе использования интеллектуальных компонентов, и ее реализация в виде аналитического программного комплекса.

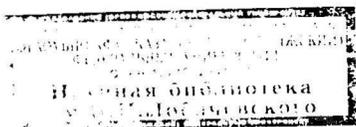
Задачи исследования:

1. Провести теоретический анализ существующих моделей прогнозирования временных рядов.
2. Исследовать возможности применения нейронных сетей для автоматизированного прогнозирования временных рядов.
3. Разработать модель комплексной предобработки временных рядов и алгоритмы адаптации нейросетевой модели.
4. Разработать программный комплекс, использующий в качестве аналитического блока модель адаптивного нейропрогнозирования.
5. Разработать механизмы интеграции нейросетевого блока в состав гибридной экспертной системы.
6. Провести имитационные вычислительные эксперименты с использованием созданного аналитического комплекса и проанализировать полученные результаты.

Объектом исследования являются временные ряды, которые описывают динамику экономических процессов.

Предметом исследования являются методы и алгоритмы проектирования нейросетевых адаптивных моделей прогнозирования.

Методы исследования. Поставленные в диссертационной работе задачи решались с применением методов системного анализа, математического моделирования, нейросетевого моделирования, математической статистики, искусственного интеллекта и экспертных оценок, при широком использовании программно-математического инструментария.



Научные результаты и новизна работы заключается в следующем:

1. Предложена новая модель прогнозирования экономических временных рядов на основе нейросетевого и гибридного подходов.
2. Разработаны алгоритмы повышения качества прогноза за счет комплексного использования методов предобработки временных рядов, контроля адекватности прогнозных моделей и их адаптации.
3. Создан программный комплекс, реализующий построение нейросетевых и гибридных моделей прогнозирования временных рядов.

Защищаемые положения:

1. Модель прогнозирования временных рядов, включающая предварительную обработку данных, обучение и дообучение нейронных сетей.
2. Технология, алгоритмы и методы настройки системы нейропрогнозирования.
3. Аналитический программный комплекс и результаты вычислительных экспериментов прогнозирования временных рядов на примере продаж автомобилей в регионе.

Достоверность и обоснованность научных результатов и выводов основана на корректности постановок задач и используемого математического аппарата, адекватности математических моделей и проверкой на основе имитационных экспериментов.

Практическая значимость результатов диссертационной работы заключается в том, что разработанная модель и программный комплекс применяются для эффективного решения задачи прогнозирования продаж автомобилей. Полученные результаты позволяют решить ряд управленческих задач предприятий и сервисных центров таких как, получение прогноза продаж, возможность гибкого формирования плана поставок материалов и комплектующих.

В ходе работы:

- спроектированы аналитические информационные системы: «Нейро-Аналитик», «Бизнес-Аналитик», «Автопрогноз»;
- разработанный программный комплекс внедрен в составе информационной системы ОАО «Алтай-Лада».

Исследование проводилось в рамках:

- государственного контракта по теме НИОКР «Разработка технического задания и опытного образца интеллектуальной информационной системы для оценки и прогнозирования состояния экономических и социальных объектов с использованием методов нейроинформатики и гибридных экспертных систем» в 2007-2008 годах;
- единого заказ-наряда по теме «Разработка модели интеллектуальной системы для решений задач оценки и прогнозирования состояния

экономических и социальных объектов с использованием методов нейроинформатики и гибридных экспертных систем» в 2005-2010 годах.

Апробация результатов работы. Основные положения и результаты работы докладывались и обсуждались на международной научно конференции «Наука и Молодежь» (г. Барнаул) в 2005-2008 годах, на научно-практической конференции «Молодежь – Барнаулу» (г. Барнаул) в 2006-2009 годах, на всероссийском семинаре «Нейроинформатика и ее приложения» (Институт вычислительного моделирования СО РАН, г. Красноярск) в 2006-2009 годах, на научно-технической конференции «Виртуальные и интеллектуальные системы» (г. Барнаул) в 2006-2009 годах.

Публикации. По теме диссертации опубликовано 10 работ, в т.ч. две в журналах рекомендованных ВАК, получено три свидетельства о регистрации программных продуктов.

Структура диссертации. Диссертационная работа состоит из введения, трех глав, заключения, списка использованной литературы и двух приложений общим объемом 196 страниц, содержит 42 рисунка, 35 таблиц.

ОБЩЕЕ СОДЕРЖАНИЕ РАБОТЫ

Во введении показана актуальность диссертационного исследования, сформулирована цель и задачи для ее достижения, определены объект и предмет работы, методы исследования, научная новизна и положения, выносимые на защиту, теоретическая и практическая значимость.

Первая глава посвящена анализу существующих методов прогнозирования временных рядов. Рассматриваются такие статистические методы, как: адаптивные модели, регрессионный анализ, кривые роста, частотный анализ. Недостатки классических методов прогнозирования временных рядов обусловливает трудность их использования для решения задачи автоматизированного прогнозирования и построения автоматизированных прогнозирующих систем.

Преимуществом нейронных сетей в задачах прогнозирования является возможность использования опыта, возможность оперативного дообучения; определение значимости входных показателей и работа с зашумленными и неполными данными. В контексте данной работы под нейросетью понимается сложная вектор-функция:

$$y_{i_n}^{(n)} = f \left(\sum_{i_{n-1}=1}^{k_{n-1}} w_{i_{n-1}, i_n}^{(n)} f \left(\sum_{i_{n-2}=1}^{k_{n-2}} w_{i_{n-2}, i_{n-1}}^{(n-1)} \dots f \left(\sum_{i_0=1}^{k_0} w_{i_0, i_1}^{(0)} x_{i_0} \right) \right) \right),$$

где n – число слоев сети; i_n – номер нейрона на слое n ; w – вектор параметров или синаптических весов связей; x – вектор входных переменных; k_n – число

нейронов в n -ом слое; $f(s) = s/(a + |s|)$ – нелинейная функция поведения нейрона; s – выход сумматора нейрона; $a > 0$ – параметр функции $f(s)$.

Также в первой главе рассматривается важность проблемы предобработки временных рядов и подготовки их для качественного обучения нейронной сети. Показана возможность улучшения качества прогноза за счет использования нейросетевого блока прогнозирования в составе иерархической гибридной экспертной системы.

Задачу прогнозирования при помощи нейронной сети можно представить в следующем виде: $Y = N(y_1, y_2, \dots, y_n)$, где Y – прогнозное значение; N – нейросетевая функция; y_1, y_2, \dots, y_n – n предыдущих значений временного ряда. Переходя к модели, включающей комплексную предобработку временного ряда, обозначим: $M = \langle V, P, F, O, N \rangle$, где V – исходный временной ряд; P – алгоритм повышения информативности; F – алгоритм фильтрации; O – окно погружения; N – нейронная сеть.

Множество $\tilde{M} = \{M_1, M_2, \dots, M_n\}$ – варианты создания нейросетевой модели прогнозирования. Тогда задача построения оптимальной прогнозной модели представляется в виде $E = \|Y_i - Y_0\| \rightarrow \min$, где Y_i – прогнозные значения i -ой модели; Y^0 – фактические значения; E – ошибка i -ой прогнозной модели. Оптимальная прогнозная модель находится решением задачи: $M_{opt} = \operatorname{argmin}\{G(V, P, F, O, N) | M_{opt} \in \tilde{M}\}$.

В диссертационной работе проведен системный анализ методов решения сформулированной задачи поиска оптимальной модели прогнозирования экономических временных рядов, и обосновано создание модели прогнозирования временных рядов, включающей предварительную обработку данных, обучение и дообучение нейронных сетей.

Во второй главе описана общая структура информационных систем, использующих интеллектуальные аналитические модули, представленная на рисунке 1. Интеллектуальные модули представлены в виде гибридных экспертных систем $\{\GammaЭС_1, \GammaЭС_2, \dots, \GammaЭС_n\}$, в составе которых используются нейросетевые адаптивные блоки $\{НС_1, НС_2, \dots, НС_G\}$, с модулями датчиков $\{МД_1, МД_2, \dots, МД_n\}$. На вход датчиков поступают измеряемые показатели процесса, на основе которых рассчитываются коэффициенты $\{K_1, K_2, \dots, K_m\}$; значения коэффициентов используются модулями принятия решений $\{МПРД_1, МПРД_2, \dots, МПРД_n\}$. Далее они поступают в блок принятия решения более высокого уровня, для управления дальнейшей работой интеллектуального блока.

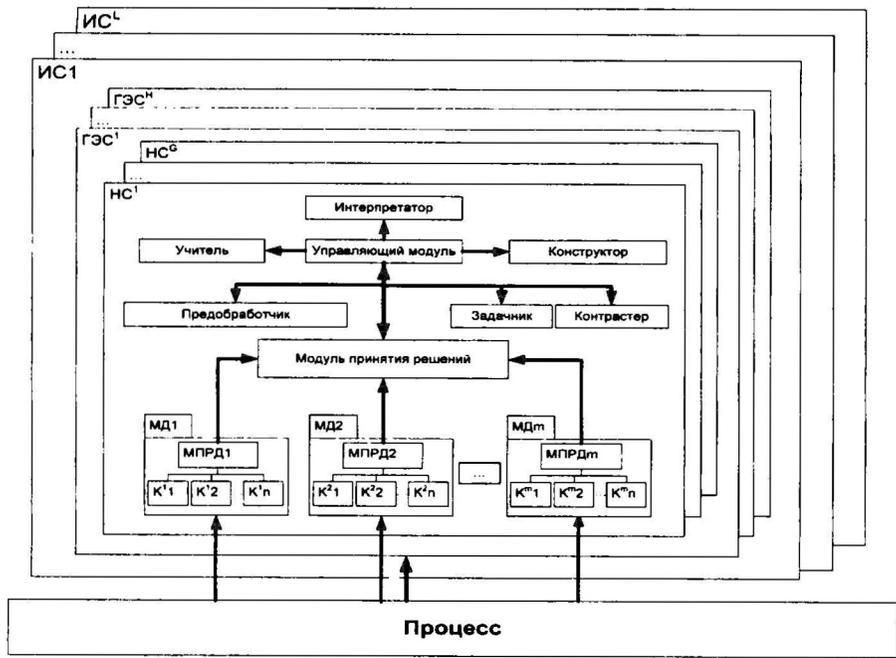


Рисунок 1 – Архитектура информационных систем с интеллектуальными компонентами

Представленная система позволяет осуществлять контроль за следующими этапами создания прогнозной нейросетевой модели: проверка однородности данных, фильтрация ряда, повышение информативности данных, погружение ряда, формирование комитета сетей, контроль адекватности модели. На рисунке 2 представлена модель нейросетевого блока с адаптивными датчиками.

В состав каждого контролирующего блока входит модуль датчика, перечень рассчитываемых коэффициентов, а также модуль принятия решений, в котором в виде правил продукции заложен алгоритм действий в зависимости от значений коэффициентов.

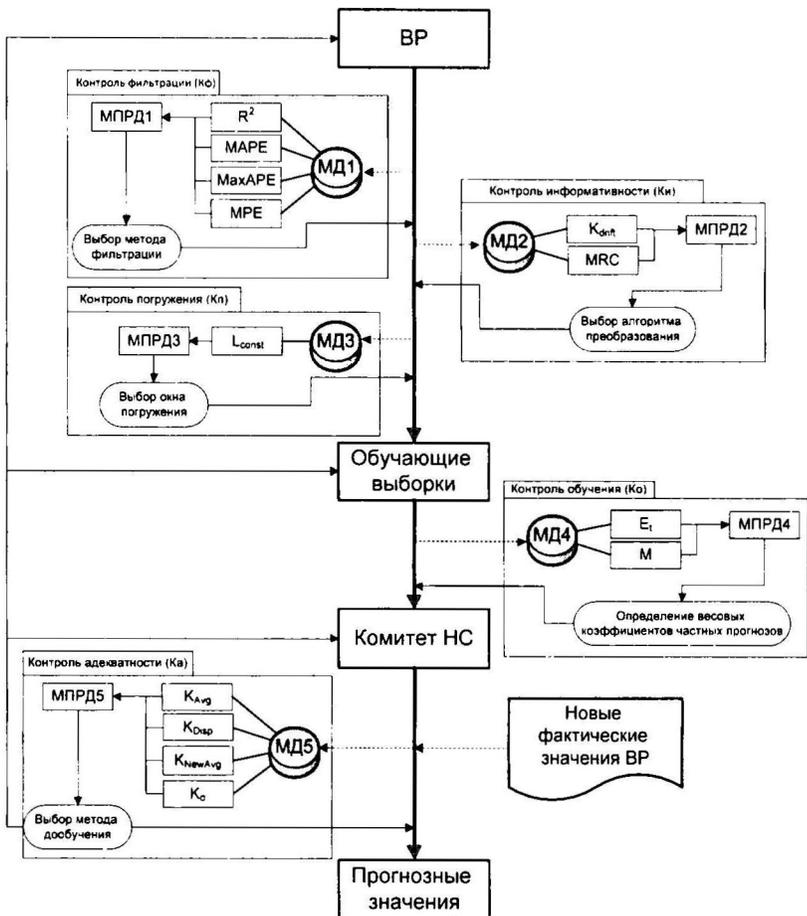


Рисунок 2 – Модель адаптивного нейросетевого блока

При помощи методов фильтрации снижается размерность ряда, отделяются трендовые изменения от нетрендовых. В модели используются следующие методы фильтрации: скользящее среднее, экспоненциальное сглаживание, вейвлет-преобразование. Алгоритм датчика позволяет выбрать метод

фильтрации на основании следующих показателей: $MAPE = \frac{\sum_{t=1}^N \left| \frac{e_t}{y_t} \right|}{N}$ – средняя

абсолютная ошибка, $MaxAPE = \max \left| \frac{e_t}{y_t} \right|$ – максимальная абсолютная ошибка,

$MPE = \frac{\sum_{t=1}^N e_t}{N}$ – средняя ошибка, $R^2 = 1 - \frac{\sum_{t=1}^N e_t^2}{\sum_{t=1}^N (y_t - \bar{y})^2}$ – коэффициент детерми-

нации, где N – количество значений ряда; y_t – значение ряда; e_t – ошибка модели фильтрации; \bar{y} – среднее значение. Контроль превышения критических значений данных показателей позволяет не использовать большую часть неудачно примененных алгоритмов фильтрации.

В результате этапа повышения информативности временной ряд может быть преобразован к виду: $y'_1 = y_1 - y_{1-1}$, $y'_i = \frac{y_i}{y_{i-1}}$, $y'_i = \frac{y_i - y_{i-1}}{y_{i-1}}$. Показатели, которые влияют на алгоритм преобразования: $K_{\text{drift}} = \max_{i \neq j} \left| \frac{\text{Avg}(m_i)}{\text{Avg}(m_j)} \right|$, $MRC = \frac{\sum_{i=1}^N |y_i - y_{i-1}|}{\sum_{i=1}^N |y_i|}$.

Заключительным этапом подготовки временного ряда к обучению нейронной сети является его погружение в N -лаговое пространство. Для погружения используется метод «скользящего окна». После формирования обучающей выборки осуществляется дополнительный контроль над моделированием. Для сформированной обучающей выборки рассчитывается константа Липшица: $L_{\text{CONST}} = \max_{i \neq j} \frac{|f^i - f^j|}{|x^i - x^j|}$, где f – таблично заданная функция, которая в точках x^i принимает значения f^i . На основе анализа константы Липшица делается заключение о том, насколько удачно выбрано вид и размер окна погружения.

После окончания обучения контролируется адекватность созданных моделей. Адекватными моделями считаются такие, у которых остаточная компонента имеет свойства независимости и нормальности распределения. Для оценки адекватности созданных моделей используется один из наиболее распространенных показателей для проверки корреляции внутри ряда – критерий Дарбина-Уотсона: $D = \sum_{i=2}^n (e_i - e_{i-1})^2 / \sum_{i=1}^n e_i^2$, где e_i – расхождение между фактическими и расчетными уровнями.

В результате конструирования прогнозных моделей чаще всего получается не одна, а несколько моделей обладающих удовлетворительными характеристиками. В этом случае строится обобщенный прогноз, основанный на использовании комитета нейронных сетей. Формируется он как линейная комбинация частных прогнозов сетей – $Y' = \sum_{j=1}^M y_j p_j$, где M – число объединяемых прогнозов; p_j – весовые коэффициенты частных прогнозов; y_j – частные прогнозы. Весовые коэффициенты определяются из условия минимума дисперсии ошибок обобщающего прогноза, т.е. максимума его точности.

Кроме режима обучения в интеллектуальных информационных системах важную роль играет режим дообучения. Контроль адекватности функционирует по алгоритму, представленному на рисунке 3. В общем случае модель нейропрогнозирования считается адекватной до тех пор, пока в систему не поступает достаточное количество данных, на основании которых

принимается решение о необходимости изменения параметров модели. Такой же вывод можно сделать на основе анализа результатов прогнозирования выдаваемых самой моделью.



Рисунок 3 – Процесс дообучения при функционировании нейросетевой системы прогнозирования

В существующей модели при поступлении нового фактического значение вычисляются следующие индикаторы: $K_{Avg} = \frac{Avg(BP_{исходный})}{Avg(BP_{текущий})}$, $K_{Disp} = \frac{Disp(BP_{исходный})}{Disp(BP_{текущий})}$, $K_{NewAvg} = \frac{Avg(BP_{исходный})}{Avg(BP_{новый})}$, $K_{\sigma} = \left| \frac{X - \bar{X}}{\sigma} \right|$, где $Avg()$ – среднее значение временного ряда; $Disp()$ – дисперсия значений временного ряда; σ – стандартное отклонение; X – новое значение временного ряда; \bar{X} – среднее значение текущей выборки. Далее рассчитанные индикаторы поступают на вход продукционной экспертной системе, в которую в виде правил заложен алгоритм дообучения (рис. 4). Алгоритм представляет собой множество конъюнктивных правил вида: $Pr: (d(K_{Avg}) \in D(K_{Avg}), d(K_{Disp}) \in D(K_{Disp}), d(K_{NewAvg}) \in D(K_{NewAvg}), d(K_{\sigma}) \in D(K_{\sigma})) \rightarrow d(Decide)$, где $d(x)$ – текущее значение параметра x ; $D(x)$ – множество интервалов определенное для параметра x .

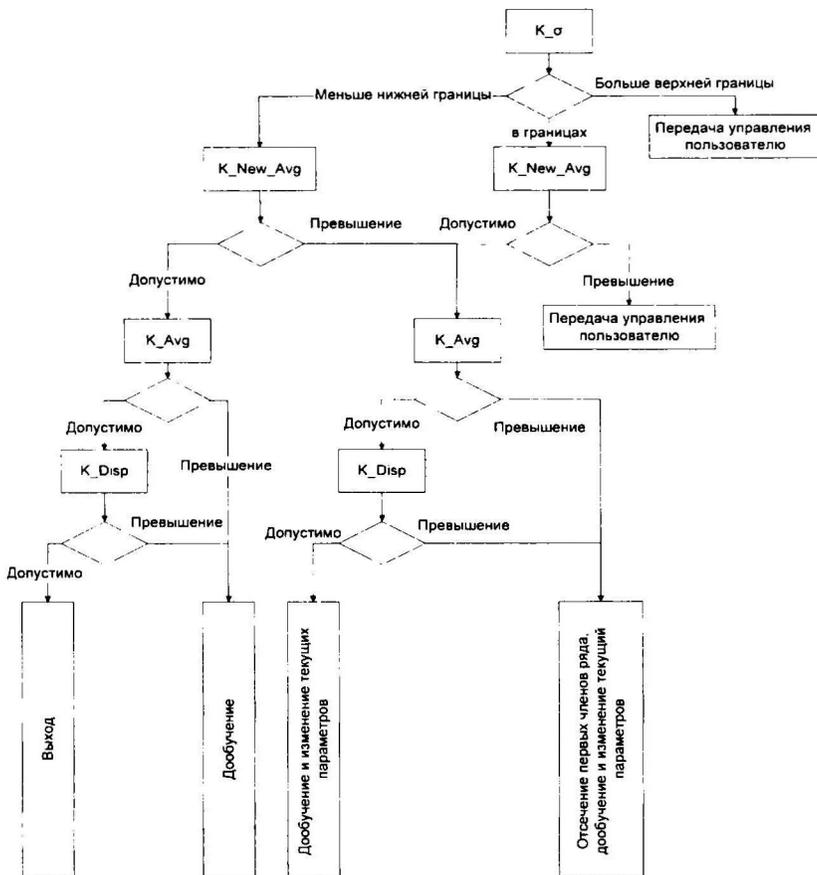


Рисунок 4 – Дерево решений алгоритма дообучения при прогнозировании временных рядов

Структура нейросетевого программного комплекса, реализующего описанные алгоритмы и методы системы нейропрогнозирования, представлена на рисунке 5.

Далее во второй главе описан процесс построения гибридной экспертной системы, расширяющей функционал системы прогнозирования. Данный подход позволяет наиболее адекватным образом скорректировать прогноз с учетом не только количественных, но и качественных факторов, а также экспертных оценок.

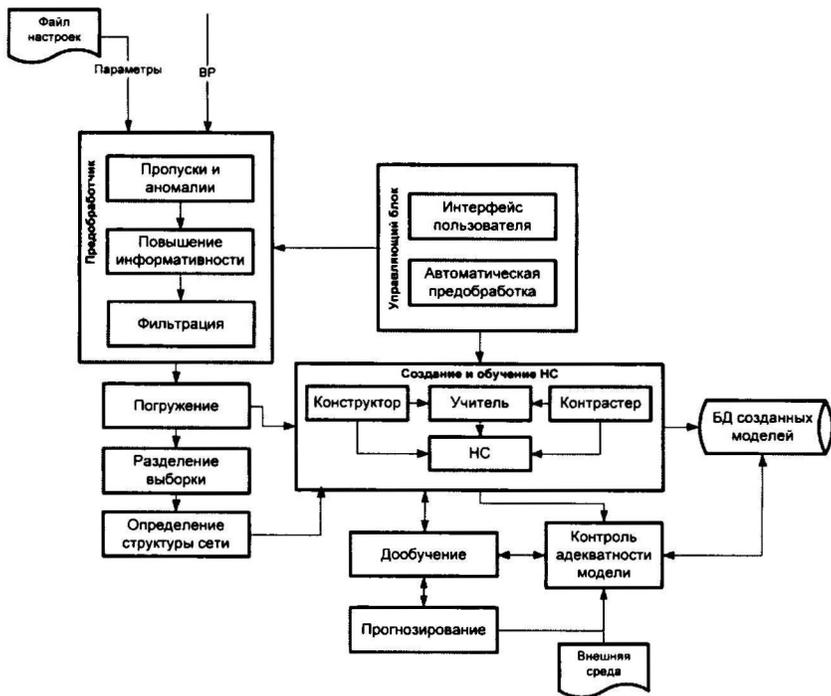


Рисунок 5 – Структура нейросетевого блока в составе гибридной системы прогнозирования временных рядов

Процесс принятия управленческого решения на основании прогноза продаж и анализа внешней рыночной ситуации поддерживают следующие участники: $Exp = \{Exp_a, Exp_b, Exp_c\}$ – эксперты; $Lpr = \{Lpr_a, Lpr_b, Lpr_c\}$ – лица принимающие решения (ЛПР). Задача эксперта – проанализировать рыночную ситуацию ($Market$) и представить ее в удобной для ЛПР виде. ЛПР на основании результатов прогноза продаж и мнения эксперта принимает управленческое решение $Decide_a$. При этом задача усложняется при участии в процессе несколько экспертов или ЛПР. Представление информации об окружающей среде (условиях, в которых находится рынок) в тезаурусе одного эксперта: $Market \xrightarrow{Exp_a} Market_a$. При участии нескольких экспертов получаем $Market_a, Market_b, Market_c$, причем $Market_a \neq Market_b \neq Market_c$. При этом $Market_{a,b,c} = Market_a \cup Market_b \cup Market_c$ – может абсолютно не

совпадать с реальными параметрами рынка и включать в себя противоречия, а $Market_{a,b,c} = Market_a \cap Market_b \cap Market_c$ может быть пустым. Решение ЛПР принятым на основании данного анализа выглядит следующим образом:

$$Decision_x = \begin{cases} Market & \xrightarrow{Exp_a} Market_{a,b,c} \\ Forecast & \xrightarrow{Lpr_x} Decision \end{cases}$$

В случае участия в процессе ЛПР возникает проблема неоднозначной трактовки прогноза и нечеткого принятия решения. Таким образом, при построении аналитического дерева решались две задачи: агрегация мнений экспертов и обобщение алгоритмов принятия решений ЛПР. Первая задача решалась с использованием экспертных опросов, взаимным оцениванием экспертов и определением коэффициентов значимости для каждого эксперта. Вторая задача решалась путем определения лингвистических переменных в узлах дерева и задания соответствующих функций принадлежности.

В результате была построена модель прогнозирования на основе гибридного подхода в виде совокупности: $M = \langle X, D, F, L \rangle$, где X – множество параметров ПО; D – множество доменов параметров; F – множество функциональных отношений, определяющих зависимости между различными параметрами; L – сеть функциональных связей параметров. Графически данную модель можно представить в виде направленного графа (рис.6). В истоках графа располагаются входные параметры, в стоках – выходные параметры. Каждому параметру соответствует домен $D(x_i)$ – множество дискретных или непрерывных значений, которые может принимать параметр. Кроме параметров, принимающих количественные значения, в модель включены и качественные параметры, принимающие лингвистические значения. В процессе вывода при решении конкретной задачи на модели каждый параметр принимает определенное текущее значение, надежность которого оценивается фактором уверенности $KF(d(x_i)) \in [0,1]$. Фактор уверенности вычисляется с помощью формул нечеткой логики при выводе значения параметра с помощью функциональных зависимостей. Связь между входными и выходными показателями модели в узлах использования экспертной системы задается с помощью формализации знаний ЛПР в виде продукционных правил следующего вида: $\langle NameAvto, Date, P(K), A \rightarrow \{B_1, B_2, \dots, B_N\} \rangle$, где $NameAvto$ – наименование группы автомобилей; $Date$ – дата прогнозирования; $P(KF)$ – условие применимости продукции – нечеткий предикат, связанный с коэффициентом уверенности KF ; $A \rightarrow \{B_1, B_2, \dots, B_N\}$ – недетерминированное ядро продукции, интерпретируемое выражением типа «Если A , то с уверенностью KF реализовать B_1, B_2, \dots, B_N ».

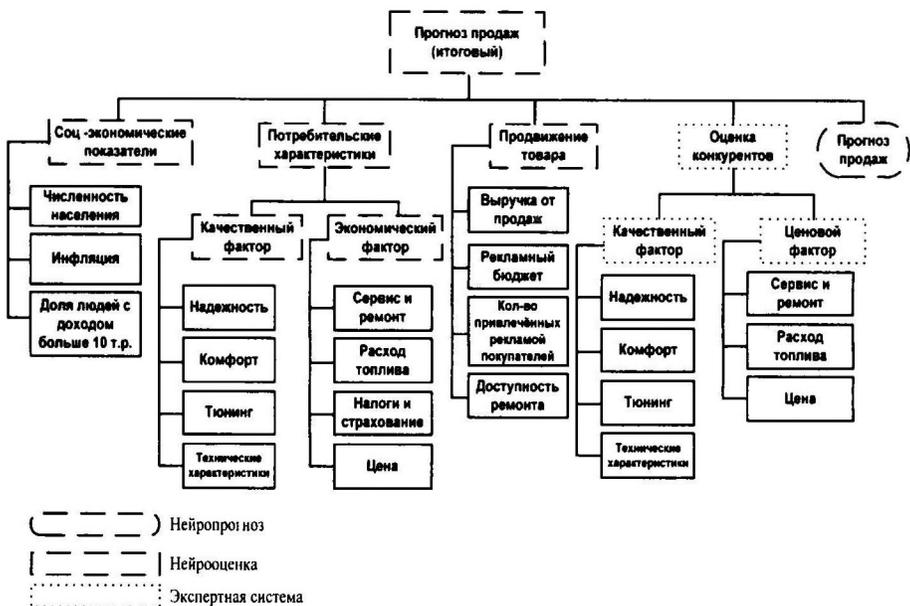


Рисунок 6 – Структура гибридной экспертной системы

Прогноз продаж (итоговый) является целевой вершиной аналитического дерева. Социально-экономические показатели позволяют сделать выводы об изменении потенциального рынка автомобилей и количества платежеспособного населения. Группа потребительских характеристик позволяет оценить непосредственно изучаемый автомобиль. Потребительские характеристики включают в себя две группы показателей: экономические и качественные показатели. Оценка эффективности продвижения показывает насколько клиенты и потенциальные клиенты осведомлены о наших автомобилях, сервисных услугах, насколько эти услуги им доступны. Оценка конкурентов является показателем аналогичным «потребительским характеристикам», но отражает качественные характеристики автомобилей конкурентов. Прогноз продаж – это узел, который выдает прогноз продаж при помощи только нейросетевой модели прогнозирования.

В целом, во второй главе предложена модель анализа, предобработки и прогнозирования временных рядов, использующая преимущества методов прогнозирования на базе нейронных сетей и гибридных экспертных систем. Разработан комплексный алгоритм предобработки временных рядов, включающий автоматическое прохождение всех этапов.

В третьей главе рассмотрены: основные конструктивные особенности информационной системы нейропрогнозирования; результаты вычислитель-

ных экспериментов по созданию нейросетевой модели прогнозирования, ее адаптации, а также использованию в составе гибридной модели. Средством программной реализации аналитического программного комплекса являлась среда разработки Visual Studio 2008. Эффективность использования созданного программного комплекса подтверждается результатами сравнения прогнозных значений, полученных с помощью адаптивного нейросетевого комитета, и значений полученных при помощи других методов прогнозирования. Результаты сравнения приведены в таблице 1.

Таблица 1 – Сравнение моделей

Модель	Относительная ошибка прогноза (%)
Хольта-Уингерса	51,2
AR	45,3
MA	47,8
ARIMA	38,1
Нейросеть	35,6
Нейросетевой комитет	29,5

Эксперимент по адаптации прогнозной модели проводился в условиях поступающих новых данных о продажах автомобилей. Для проверки алгоритмов адаптации использовались данные о ежемесячных продажах автомобилей семейства «Классика». Предварительном ходе имитационного эксперимента были получены следующие значения коэффициентов используемых датчиком контроля адекватности: $K_{Avg} = 0.08$, $K_{Disp} = 0.07$, $K_{NewAvg} = 0.5$, $K_{\sigma} = 1.5$. В результате эксперимента были рассчитаны моменты срабатывания. Процесс дообучения был запущен на 6, 13, 14, 17 и 21 шагах поступления новых значений (выделены в таблице 2).

Таблица 2 – Новые фактические данные, точки срабатывания индикаторов

№	Дата	X	\bar{X}	σ	K_{σ}	K_{Avg}	K_{Disp}	K_{NewAvg}
1	01.10.2006	39	100	45,37	1,40	0,02	0,03	
2	01.11.2006	60	99	45,21	0,93	0,03	0,02	
3	01.12.2006	42	97	45,55	1,33	0,04	0,03	
4	01.01.2007	51	96	45,55	1,13	0,06	0,03	
5	01.02.2007	65	95	45,21	0,82	0,07	0,02	
6	01.03.2007	28	93	45,89	1,64	0,08	0,05	
7	01.04.2007	60	92	45,60	0,72	0,01	0,01	
8	01.05.2007	61	92	45,29	0,70	0,02	0,03	
9	01.06.2007	41	90	45,40	1,14	0,03	0,02	
10	01.07.2007	46	89	45,37	1,03	0,04	0,02	
11	01.08.2007	42	88	45,41	1,12	0,05	0,02	0,48
12	01.09.2007	37	87	45,54	1,22	0,06	0,02	0,49
13	01.10.2007	29	86	45,84	1,40	0,08	0,00	0,49
14	01.11.2007	40	85	45,84	1,00	0,01	0,00	0,50
15	01.12.2007	22	84	46,23	1,39	0,03	0,02	0,49

16	01.01.2008	30	83	46,38	1,22	0,04	0,02	0,49
17	01.02.2008	32	82	46,45	1,18	0,05	0,03	0,50
18	01.03.2008	21	80	46,76	1,30	0,01	0,01	0,49
19	01.04.2008	35	79	46,73	1,00	0,03	0,01	0,49
20	01.05.2008	38	79	46,62	0,94	0,03	0,01	0,49
21	01.06.2008	24	78	46,78	1,24	0,05	0,01	0,50

Эффективность механизма динамической адаптации прогнозной модели видна из таблицы 3, в которой приведены относительные ошибки прогнозов. Ошибки приведены для начальной модели, для модели проходящей процедуру дообучения на каждом шаге и для модели, дообучающейся в выявленных точках.

Таблица 3 – Ошибки прогнозов

Шаг	Без дообучения	Дообучение на каждом шаге	Дообучение
01.10.2006	39.7%	39.7%	39.7%
01.03.2007	42.5%	42.6%	36.2%
01.10.2007	38.2%	44.4%	31.6%
01.11.2007	45.4%	38.2%	27.5%
01.02.2008	48.4%	34.9%	23.2%

Прогноз, полученный при помощи нейросетевого комитета, входит в состав общей структуры гибридной экспертной системы, которая позволяет реагировать на изменение различных экономико-социальных показателей. В ходе проведения эксперимента прогнозирования продаж при помощи гибридной экспертной системы, ставилась задача проанализировать поведение спроса в результате изменения входных показателей. Результаты прогнозирования продаж с использованием ГЭС и результаты анализа различных рыночных ситуаций представлены в таблице 4.

Таблица 4 – Анализ рыночных ситуаций

Анализируемая ситуация	01.06.2007	01.07.2007	01.08.2007	01.09.2007
Нейропрогноз	55	61	61	75
Уменьшение цены на 10%	57	63	64	78
Уменьшение цены на 20%	61	68	68	83
Увеличение цены на 10%	54	59	59	72
Увеличение цены на 20%	49	53	54	64
Уменьшение надежности на 10%	54	59	59	73
Увеличение надежности на 10%	55	62	63	77
Уменьшение комфорта на 10%	55	60	59	72
Уменьшение показателей «Комфорт», «Надежность» на 20%, при уменьшении цены на 10%	56	61	60	77
Реальные данные	62	64	60	80

Модель адекватно реагирует на изменения в предметной области, что позволяет сделать вывод об эффективности использования гибридного подхода при решении задачи прогнозирования продаж автомобилей. Наблюдается линейность зависимости прогнозных значений от входных параметров. Однако во многом это обуславливается небольшим объемом знаний, заложенных в модель, и недостаточным количеством экспертов, привлеченных к настройке системы. Эффективность гибридной экспертной системы прогнозирования продаж, продолжает повышаться специалистами и экспертами в данной области.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ РАБОТЫ

В ходе проведенных исследований в диссертационной работе были решены следующие задачи

1. Обобщены и систематизированы основные методы и модели прогнозирования временных рядов. Показана актуальность разработка новых методов и алгоритмов прогнозирования на основе нейронных сетей, делающих возможным получение эффективных прогнозных моделей с механизмом адаптации
2. Предложена модель анализа, предобработки и прогнозирования временных рядов, использующая преимущества методов прогнозирования на базе нейронных сетей и гибридных экспертных систем.
3. Предложен комплексный алгоритм предобработки временных рядов. Определены алгоритмы обработки на каждом этапе предобработки, и индикаторы эффективности этапов.
4. Разработан блок оперативного контроля за адекватностью прогнозной модели экспертная система управления блоком дообучения, реагирующая на изменения во входных данных. В ходе вычислительных экспериментов показана эффективность данного блока для адаптации прогнозной модели.

ПУБЛИКАЦИИ АВТОРА ПО ТЕМЕ ДИССЕРТАЦИИ

Работы, опубликованные автором в ведущих рецензируемых научных журналах, рекомендованных ВАК Министерства образования и науки Российской Федерации:

1. Авдеев А.С. Разработка системы автоматического конструирования нейросетевой модели прогнозирования спроса // Ползуновский вестник. – Барнаул, 2006. –№1. – С. 4–8.
2. Авдеев А.С., Пятковский О.И. Разработка программного комплекса нейропрогнозирования// Программные продукты и системы. – Тверь, 2010.– №1.– С. 106–109.

Другие публикации:

3. Авдеев А.С. Разработка адаптивной системы автоматизированного нейропрогнозирования // ИКИ-2006: сборник трудов конференции.– Барнаул, 2006. – С. 130–134.
4. Авдеев А.С. Разработка аналитической системы прогнозирования продаж автомобилей // Нейроинформатика и ее приложения: материалы XIV Всероссийского семинара. ИВМ СО РАН. – Красноярск, 2006. – С. 10–12.
5. Авдеев А.С., Пятковский О.И. Определение размера сети и окна погружения при решении задачи прогнозирования // Нейроинформатика и ее приложения: материалы XV Всероссийского семинара / ИВМ СО РАН. – Красноярск, 2007. – С. 16–17.
6. Авдеев А.С., Пятковский О.И. Адаптивная модель прогнозирования временных рядов на примере продаж автомобилей в регионе // Нейроинформатика, её приложения и анализ данных: материалы XVII Всеросс. Семинара / ИВМ СО РАН. – Красноярск, 2009. – С. 9–12.
7. Авдеев А.С. Разработка модели адаптивной автоматизированной системы нейропрогнозирования //Ползуновский альманах.–2006, №4. – С. 4–6.
8. Авдеев А.С. Интеллектуальный блок прогнозирования для систем на платформе 1С 8.1 // Ползуновский альманах. – 2008. – №2.– С. 56–58.
9. Авдеев, А.С., Пятковский О.И. Концепция создания адаптивных интеллектуальных компонентов //Ползуновский альманах. – 2009. – №2.– С. 193–195.
10. Авдеев А.С., Пятковский О.И., Зиновьев А.Т. Интеллектуальные компоненты аналитических информационных систем управления организацией: учебное пособие.– Барнаул: Изд-во АлтГТУ, 2006. – 300с.
11. Авдеев А.С., Демчик Д.С., Ивкин Ю.Н., Краснюков И.А., Пятковский И.О., Пятковский О.И., Тишков О.И. Бизнес Аналитик 1.0. Свидетельство об официальной регистрации программы для ЭВМ №2005611449. – 2005.
12. Авдеев А.С., Пятковский О.И., Тишков О.И. Интеллектуальная система оценки и прогнозирования показателей (Нейро-Аналитик). Свидетельство об официальной регистрации программы для ЭВМ №2006610376. – 2006.
13. Авдеев А.С., Вагнер В.А., Машук Е.В., Пятковский О.И. Автоматизированная информационная система прогнозирования сбыта на автомобиле (Автопрогноз). Свидетельство об официальной регистрации программы для ЭВМ №2006612303. – 2006.

10-2

Подписано в печать 20.09.2010.
Печать – цифровая. Усл.п.л. 1,16.
Тираж – 100 экз. Заказ 2010 – 459.

Отпечатано в типографии АлтГТУ,
656038, г.Барнаул, пр-т Ленина, 46
тел.: (8-3852) 36-84-61

Лицензия на полиграфическую деятельность
ПЛД №28-35 от 15.07.97 г.