

УДК [658.012.12:629.5.001.18](470.46):004.896

С. С. Виноградова, Н. Н. Касимов

**ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ
С ЦЕЛЮ ОПТИМИЗАЦИИ УПРАВЛЕНИЯ
СУДОСТРОИТЕЛЬНЫМ ПРЕДПРИЯТИЕМ
(НА ПРИМЕРЕ АСТРАХАНСКОГО РЕГИОНА)**

S. S. Vinogradova, N. N. Kasimov

**APPLICATION OF NEURAL NETWORK TECHNOLOGIES
IN ORDER TO OPTIMIZE THE MANAGEMENT
OF SHIP-BUILDING ENTERPRISES
(ON THE EXAMPLE OF THE ASTRAKHAN REGION)**

В целях повышения эффективности принимаемых управленческих решений необходимым является прогнозирование изменения значений показателей, описывающих внутреннюю и внешнюю среду судостроительного предприятия. Высокие цены на строящиеся суда – одна из основных «слабых» сторон отечественных судостроителей. Использование нейросетевых технологий в задачах снижения себестоимости продукции позволит получить положительный результат благодаря прогнозированию динамики стоимости закупаемого сырья и материалов. Обученные нейронные сети дают достаточно быстрое решение, что позволит использовать их в динамической среде, требующей незамедлительного реагирования, а аппарат нейросетевого моделирования позволит быстро корректировать модель, что делает нейронные сети удобными в создании адаптивных моделей.

Ключевые слова: судостроительно-судоремонтная отрасль, устойчивое развитие, прогнозирование, нейронные сети.

It is necessary to predict changes of indices values, which describe inner and outer environment of a shipbuilding enterprise, in order to increase the efficiency of management decisions. High cost of ships under construction is one of weak points of ships constructed in Russia. The application of neural network technologies in the solution of the problem of high costs reduction will allow to get a positive result due to the prediction of dynamics of raw materials cost. Trained neural systems make a decision rather quickly, and it will allow to use them in dynamic environment, which requires momentous feedback. The device of neural network modeling will enable to correct the model, which makes neural networks convenient for creating adaptive models.

Key words: shipbuilding-repairing industry, sustainable development, prediction, neural network.

Астраханская область, в силу своего географического положения, является стратегически важным транспортным узлом. По территории региона проходит международный транспортный коридор (МТК) «Север – Юг», связывающий страны Южной и Юго-Восточной Азии через территорию Ирана, Каспийское море и Астраханскую область с Центральной Россией и государствами Северной, Центральной и Восточной Европы. Геополитическое положение Астраханской области исторически предопределило формирование на ее территории судостроительно-судоремонтного комплекса. Судостроительно-судоремонтная отрасль оказывает значительное влияние на экономику Астраханского региона, являясь одной из градообразующих отраслей, поэтому устойчивое развитие судостроительных предприятий оказывает непосредственное влияние на устойчивое развитие Астраханской области в целом.

В настоящее время на территории Астраханской области осуществляют производственную деятельность 15 крупных судостроительно-судоремонтных заводов, динамика объема валовой продукции которых представлена на рис. 1.




Рис. 1. Объем валовой продукции по предприятиям судостроения, судоремонта в 2010 г., млн руб. (основная деятельность). Источник: Администрация Астраханской области

На рис. 1 виден рост объема производства, особенно в 2008 г. Данный скачок связан с тем, что в 2008 г. были завершены крупные заказы для иностранных компаний и компаний нефтегазового сектора. Благодаря заказам ОАО «Нефтяная компания «Лукойл» судостроительные предприятия Астраханской области увеличили за период 2005–2007 гг. выпуск продукции более чем в 4 раза. Предприятия отрасли способны строить буровые установки, нефтяные танкеры, суда рефрижераторного флота, транспортные, нефтеналивные, рыболовецкие суда, прогулочные катера, яхты и др.

Астраханские судостроительные предприятия имеют опыт работы с зарубежными партнерами, их заказчиками являются: «Agip KCO», «Rozetti Marino Spa», «Saipem» (Италия), «Svithoid Tankers A. B.» (Швеция), «Rensen Shipbuilding B. Y.» (Голландия), шотландская фирма «Крейн Марин Контрактор», фирмы «Vagenborg Uniteam», «Bue Marine», «Fjellstrand», «Emtunga», «CHNGS», «RR Offshore» и др.

Для оценки потенциала устойчивого развития предприятий судостроительно-судоремонтной отрасли Астраханской области проведем первичный SWOT-анализ с целью определения «узких» мест в работе судостроительно-судоремонтных предприятий Астраханского региона (табл. 1).

Таблица 1

Анализ состояния судостроительно-судоремонтной отрасли Астраханского региона

Сильные стороны	Слабые стороны
<p>Удачное геополитическое положение региона. Наличие крупной промышленной базы. Наличие коммерческих связей и контрактов с отечественными и зарубежными компаниями. Наличие богатого опыта и давних традиций. Положительная динамика объема выпускаемой продукции</p>	<p>Физический и моральный износ основных производственных фондов (ОПФ). Отставание от передовых предприятий. Высокая цена продукции. Большие энергозатраты и накладные расходы, высокая себестоимость продукции. Нехватка квалифицированных кадров. Низкий уровень автоматизации работ. Отсутствие построечно-спусковых сооружений для строительства и ремонта крупнотоннажных речных и морских судов дедевром более 100 тыс. т. Организация производства и труда отличается от организации производства и труда ведущих зарубежных компаний</p>
Возможности	Угрозы
<p>Государственные заказы на строительство судов Освоение новых нефтегазовых месторождений. Развитие МТК «Север – Юг» и увеличение объема морских грузоперевозок на Каспии, вызывающее рост потребности в судоремонтных работах. Развитие рыбной отрасли и туристического бизнеса в Каспийском регионе</p>	<p>Аварийное состояние ОПФ и угроза списания. Старение персонала и угроза кадрового дефицита. Длительность производственного цикла по сравнению с зарубежными компаниями. Высокая трудоемкость производственного процесса</p>

Результаты анализа позволяют сделать вывод, что потенциал для устойчивого развития судостроительных предприятий Астраханского региона кроется не только в выгодном географическом положении, но и в перспективном развитии МТК «Север – Юг», рыбной отрасли, туристического бизнеса на Каспии, а также освоении новых нефтегазовых месторождений. Однако такие параметры, как «Сильные стороны» и «Возможности» существуют наряду с такими, достаточно значительными, как «Угрозы» и «Слабые стороны», указывающими на необходи-

мость обновления ОПФ, преодоления технологического отставания от зарубежных судостроителей и оптимизации, снижения издержек производственных процессов, совершенствования управления, организации производства и труда.

Лидером по объему заказов на постройку новых судов в настоящее время является Китай – 37 % (доля российского судостроения на мировом рынке составляет 0,2 %) [1]. Предлагая самые низкие цены и короткие сроки изготовления, судостроительная отрасль Китая обеспечивает массовое распространение собственной продукции. Высокие цены – одна из основных «слабых сторон» как астраханских, так и российских судостроителей в целом, поэтому целью данной статьи будет обоснование эффективности применения нейросетевых технологий для снижения себестоимости производимой продукции и создание методики нейросетевого прогнозирования изменения курса цен на сталь, с целью сокращения расходов, связанных с неблагоприятными возможными отклонениями от планируемого уровня цен.

Начиная с конца 70-х гг. 20 в., для прогнозирования динамики экономических временных рядов начинают применяться методы теории нечетких множеств, т. к. функционирование систем происходит в условиях нечеткости и неопределенности, которые вносит одновременное воздействие человеческого и неизмеримого числа других факторов различной природы и направленности, не подлежащих совокупной оценке. Именно нечеткие представления лежат в основе нейронных сетей. Нейронные сети применяются в задачах автоматизации процессов распознавания оптических или звуковых сигналов, адаптивного управления, аппроксимации функций, прогнозирования, в том числе предсказания изменения котировок, прогнозирования изменений экономических показателей и во многих других приложениях. Однако, в отличие от зарубежных фирм, российские организации не столь широко используют нейронные сети в практических целях.

Чем могут помочь в задачах прогнозирования нейронные сети? Нейронные сети можно рассматривать как обобщение традиционных методов анализа и моделирования. Они дают дополнительные возможности в моделировании нелинейных явлений и распознавании хаотического поведения. Нейронные сети применимы практически в любой ситуации, когда имеется связь между входными переменными (имеющимися данными) и прогнозируемыми переменными, даже если эта связь имеет сложную природу. Предлагается использовать нейросетевое моделирование в дополнение к традиционным методам анализа данных.

Анализ литературы показал, что нейронные сети лучше других методов анализа [2–5]. Преимуществом нейронных сетей является их самообучаемость. Процедура обучения состоит в настройке синаптических весов с целью минимизации функции ошибок. Обученные нейронные сети дают достаточно быстрое решение, что позволяет использовать их в динамической среде, требующей незамедлительного принятия решений, а аппарат нейросетевого моделирования позволяет быстро корректировать модель, что делает нейронные сети удобными в создании адаптивных моделей.

Типичная последовательность действий при решении задачи прогнозирования показателей с помощью нейронных сетей показана на рис. 2.

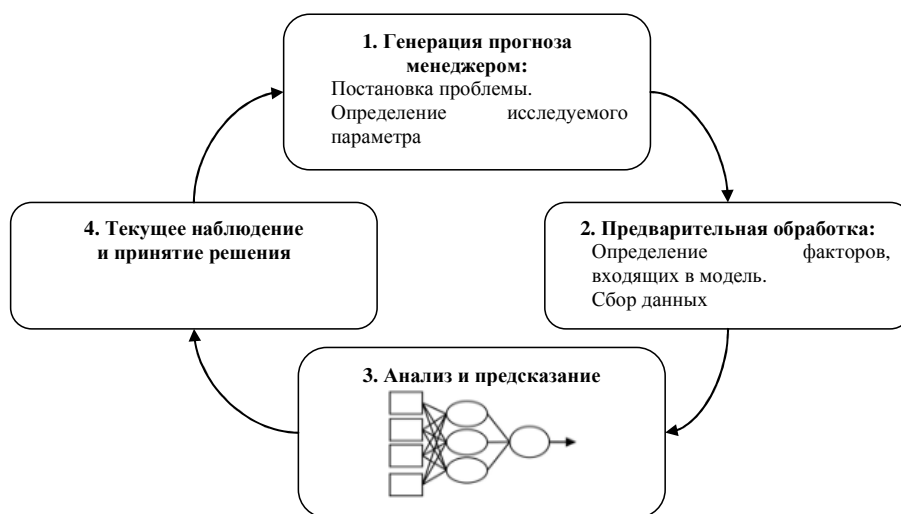


Рис. 2. Алгоритм составления прогноза с помощью нейронных сетей

На первом этапе (Постановка проблемы) было определено, что задачей прогнозирования является оценка возможности неблагоприятного отклонения от планируемого уровня цен на сталь.

На втором этапе (Предварительная обработка) необходимо определить факторы, входящие в модель и осуществить выбор числа и вида переменных, характеризующих моделируемый показатель или процесс: это могут быть комбинации переменных, прошлые значения целевой переменной, закодированные качественные показатели (например, с целью учета «эффекта дня недели»). В нашей задаче показателем будет являться динамика цен на сталь, приобретаемую у поставщиков, а прогнозирование цены будет осуществляться на основе предыдущих значений исследуемого параметра.

На третьем этапе (Анализ и предсказание) необходимо реализовать определенную последовательность действий:

1. Предварительный анализ полученных временных рядов, расчет коэффициента Херста с целью определения характеристик временного ряда.
2. Создание нейронной сети (рис. 3)
 - 2.1. Выбор топологии сети, определение числа скрытых слоев (элементов), если применяются сети с прямой связью.
 - 2.2. Выбор критерия ошибки и обучающего алгоритма.
 - 2.3. Проверка различных свойств модели на тестовом множестве.

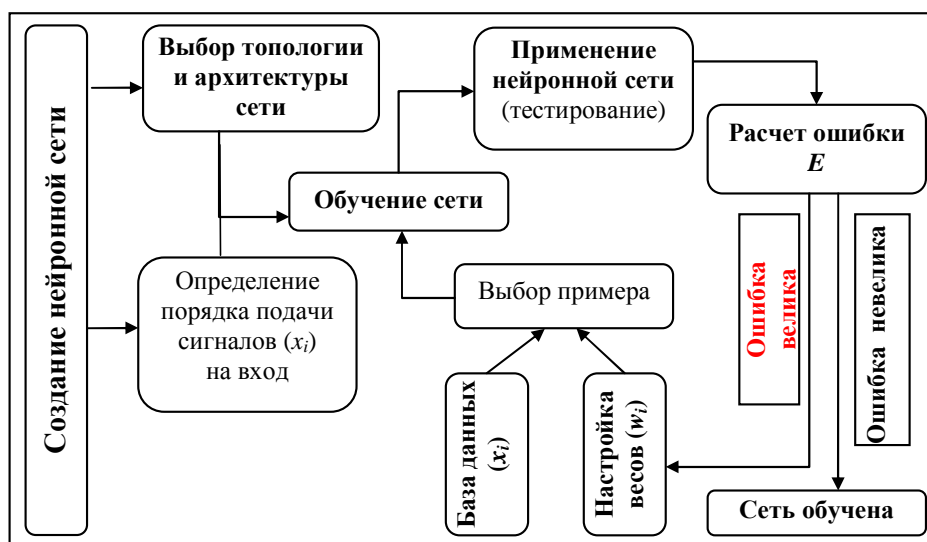


Рис. 3. Алгоритм создания нейросетевой модели

Перед тем как приступить к непосредственному нейросетевому моделированию, необходимо оценить характер прогнозируемого временного ряда и определить, возможно ли, например, создать нейросетевую модель, осуществляющую предсказание прогнозируемого параметра на основе данных о его предыдущих значениях. Для решения поставленной задачи и получения дополнительной важной практической информации об анализируемом временном ряде необходимо рассчитать коэффициент Херста. Показатель Херста (H , Hurst coefficient) отражает, насколько система может обучаться на прошлых данных, как будет вести себя в будущем, характеризуя степень зависимости между будущими и прошлыми значениями динамической системы и измеряя влияние информации на временной ряд данных.

Временные ряды, коэффициент Херста которых отличается от 0,5, не являются независимыми. Каждое значение несет память о предшествующих событиях. Это память долговременная. События, которые произошли недавно, оказывают большее влияние, чем отдаленные события, но остаточное влияние прошлого сохраняется достаточно длительное время. Чем ближе H к 0,5, тем временной ряд более зашумлен и тем менее выражен его тренд. Анализ литературы позволил выделить три наиболее значимые методики расчета коэффициента Херста [4, с. 107; 6].

Если коэффициент Херста показывает, что временной ряд обладает долговременной памятью и будет принято решение о прогнозировании показателя на основе данных о его предыдущих значениях, то подача входных данных на вход сети будет осуществляться по «методу окон». Суть данного метода заключается в использовании двух окон T_i и T_j с фиксированными размерами n и m соответственно, которые перемещаются окна с некоторым шагом по временному ряду значений анализируемого параметра, начиная с первого элемента. Первое окно T_i , получив необходимые данные, передает их на вход нейронной сети, а второе – T_j – на выход, образуя на каждом шаге пару: $T_i \rightarrow T_j$. Так, если мы зададим $n = 7$, $m = 1$, $s = 1$, где s – количество элементов временного ряда, на которое осуществляется сдвиг окон, то каждый следующий вектор получится в результате сдвига окон T_i и T_j вправо на один элемент. При этом окно T_i будет включать 7 предыдущих значений прогнозируемого параметра, которые будут одновременно подаваться на вход сети.

$$x_{n-7}, x_{n-6}, x_{n-5}, x_{n-4}, x_{n-3}, x_{n-2}, x_{n-1} \rightarrow x_n.$$

Эксперимент в программе MATLAB-2011 показал, что n для адекватного прогнозирования должно быть не менее 4. Нейронная сеть, обучаясь на этих наблюдениях и соответственно настраивая свои коэффициенты, пытается извлечь эти закономерности и сформировать в результате требуемую функцию прогноза Y . Для осуществления долгосрочного прогноза будет осуществляться многошаговое прогнозирование [7], означающее, что нейросетевая модель будет использовать полученные (выходные) данные для моментов времени x_{n+1} , x_{n+2} и т. д. в качестве входных данных для прогнозирования на следующие моменты времени соответственно.

Выбор типа нейронной сети. Анализ источников [2–5, 8, 9], посвященных проблематике нейросетевого моделирования, показал, что задачи управления, аппроксимации функций, предсказания наиболее эффективно решаются сетями со следующей архитектурой:

- многослойный перцептрон (MLP);
- радиальные базисные сети (RBF).

Эксперименты в пакете STATISTICA Neural Networks и MATLAB-2011 показали, что в задачах прогнозирования временных рядов наименьшую ошибку дают сети типа «многослойный перцептрон», поэтому более подробно будет рассмотрен материал, затрагивающий особенности построения и обучения именно сетей данного типа.

Выбор архитектуры сети – один из наиболее важных моментов нейросетевого моделирования. Согласно теореме о существовании отображения, доказанной А. Н. Колмогоровым в 1957 г. и популяризированной Р. Хехт-Нильсеном [2, с. 84], любая непрерывная функция может быть реализована трехслойной нейронной сетью, имеющей во входном слое m элементов, промасштабированных на $[0,1]$, $(2m + 1)$ элементов в скрытом слое и n элементов в выходном слое. Таким образом, гарантируется, что иерархическая многослойная нейронная сеть может решить любую нелинейно отделимую задачу и может точно реализовать любое отображение m -мерных входных векторов в n -мерные выходные. При этом теорема ничего не говорит ни о возможности реализовать отображение посредством сети меньших размеров, ни о том, что для этого подойдут обычно используемые сигмоидные преобразования.

Современные программные продукты, наиболее распространенным из которых является STATISTICA Neural Networks, дают возможность автоматизированного подбора оптимального вида и структуры нейросетевой модели, что значительно упрощает процесс моделирования. Поэтому выбор архитектуры сети предлагается осуществлять автоматизированно в пакете STATISTICA Neural Networks, а затем совершенствовать предложенную сеть в программе MATLAB, дающей более широкие возможности программирования.

Простейшая искусственная нейронная сеть состоит из группы нейронов, образующих слой. Основу каждой нейронной сети составляют однотипные элементы, имитирующие работу нейронов мозга (рис. 4). Искусственный нейрон характеризуется своим текущим состоянием и, аналогично нервным клеткам головного мозга, может находиться в возбужденном или заторможенном состоянии. Он обладает группой синапсов – однонаправленных входных связей, соединенных с выходами других нейронов, а также имеет аксон – выходную связь данного нейрона, с которой сигнал (возбуждения или торможения) поступает на синапсы следующих нейронов. Каждый синапс характеризуется величиной синаптической связи или ее весом W_i .




Рис. 4. Математическая модель нейрона

Рассмотрим структуру работы искусственного нейрона:

1. На вход нейрона поступает некоторое количество входных сигналов (x_1, x_2, \dots, x_n), образующих в совокупности вектор X .

2. Значение каждого входного сигнала умножается на вес w_1, w_2, \dots, w_n (вектор W) и поступает на суммирующий блок, где все полученные произведения суммируются, вычисляя взвешенную сумму V – потенциал нейрона.

$$V = \sum_{i=1}^N W_i x_i,$$

где N – размерность пространства входных сигналов; W_i – синаптический коэффициент или вес.

3. Полученная сумма V сравнивается с пороговой величиной W_0 , определяя уровень активации нейрона.

4. Полученная сумма преобразуется активационной функцией F в выходной нейронный сигнал, создаётся выход нейрона Y :

$$Y = F(V).$$

5. Величину порогового барьера W_0 можно рассматривать как еще один весовой коэффициент при постоянном входном сигнале. Если ввести в уравнение пороговую величину W_0 , оно переписывается так:

$$V = \sum_{i=1}^N W_i x_i + W_0,$$

где W_0 – значение смещения (bias).

Параметрами нейрона, определяющими его работу, являются: вектор весов W , пороговый уровень W_0 и вид функции активации F .

В сетях типа «многослойный перцептрон» применяются такие функции активации, как сигмоида и гиперболический тангенс, в некоторых источниках [10, с. 40] в задачах прогнозирования на выходном слое рекомендуется применять линейную функцию активации, что дает возможность выходам сети принимать произвольные значения.

Эксперименты, проведенные в программе STATISTICA Neural Networks и MATLAB-2011, показали, что наилучший результат дает применение такой функции активации, как гиперболический тангенс. Гиперболический тангенс, как и логистическая функция, является S-образной функцией, но он симметричен относительно начала координат, и в точке $V = 0$ значение выходного сигнала Y равно нулю, функция симметрична в точке $(0,0)$, что является преимуществом перед сигмоидой.

Среди всех интересных свойств искусственных нейронных сетей самым удивительным является их способность к обучению, минимизации функции ошибок. Однако возможности обучения искусственных нейронных сетей ограничены, и нужно решить много сложных задач, чтобы определить, находимся ли мы на правильном пути.

Различают алгоритмы обучения «с учителем», «без учителя» и «соревнование». Алгоритм обучения MLP – обучение «с учителем». Это означает, что сети предъявляются значения как входных, так и желательных выходных сигналов, и она по некоторому внутреннему алгоритму подстраивает веса своих синаптических связей.

Целью процедуры минимизации является отыскание глобального минимума – его достижение называется сходимостью процесса обучения. Поскольку разность между значением функции Y , вычисленным по результатам измерений, и истинным её значением (Target) зависит от весов нелинейно, получить решение в аналитической форме невозможно. Чтобы обучить нейронную сеть решению какой-либо задачи, мы должны подправлять веса каждого элемента таким образом, чтобы уменьшалась ошибка – расхождение Y и Target. Каждому из весов и порогов сети (их общее число обозначим через N) соответствует одно измерение в многомерном пространстве. Измерение $(N + 1)$ соответствует ошибке сети. Для всевозможных сочетаний весов соответствующую ошибку сети можно изобразить точкой в $(N + 1)$ -мерном пространстве, и все такие точки образуют там некоторую поверхность – поверхность ошибок. Цель обучения нейронной сети – поиск глобального минимума – осуществляется посредством обучающего алгоритма, который исследует поверхность ошибки и стремится обнаружить на этой многомерной поверхности самую низкую точку. Несмотря на более широкие (нелинейные) возможности моделирования с помощью нейронных сетей, при корректировке сети с целью минимизации ошибки невозможно быть уверенным, что нельзя добиться еще меньшей ошибки и что найден не глобальный, а локальный минимум.

Начав со случайной начальной конфигурации весов и порогов (т. е. случайно взятой точки на поверхности ошибок), алгоритм обучения постепенно отыскивает глобальный минимум. Для этого вычисляется градиент (наклон) поверхности ошибок в данной точке, а затем эта информация используется для продвижения вниз по склону. В конце концов алгоритм останавливается в нижней точке, которая может оказаться как локальным, так и глобальным минимумом.

С математической точки зрения алгоритм обратного распространения – способ быстрого расчета градиента функции ошибки, минимизирующий суммарную квадратичную ошибку E согласно методу наименьших квадратов.

$$E = \frac{1}{2} \sum_{i,k} (y_{ik}^M - t_{ik})^2, \quad (1)$$

где y_{ik}^M – выход нейрона i слоя N нейронной сети при подаче на ее входы k -го образа; t_{ik} – Target – цель или желаемое значение выхода нейрона i .

Каждая сеть задается своим вектором параметров – набором весовых коэффициентов и пороговых уровней. Таким образом, если считать обучающее множество заданным, то ошибка сети зависит только от значений указанных параметров. Минимизация ошибки ведется методом градиентного спуска, что означает подстройку весовых коэффициентов в направлении антиградиента ∇E . Методу обратного распространения ошибки посвящено большое количество научных работ [2–5, 8, 9], поэтому математическое описание метода не рассматривается.

В общем виде схема обучения перцептрона выглядит следующим образом:

1. Инициализировать веса и параметры функции активации в малые ненулевые значения. Это гарантирует, что ни один из сигмоидных элементов не насыщен (значения всех производных очень малы) и что в сети не произойдет насыщения большими значениями весов.

2. Подать на вход один входной образ и рассчитать выход $Y_i \neq T_i$, где T_i – Target – целевое значение выхода.

3. Посчитать ошибку E_i , сравнив Y_i и T_i .

4. Изменить веса и параметры функции активации так, чтобы ошибка E уменьшилась (обучающий алгоритм обратного распространения).

5. Повторить шаги 2–4 до тех пор, пока ошибка не перестанет убывать или не станет достаточно малой.

В заключение следует отметить, что вся информация, которую сеть имеет о решаемой проблеме, содержится в наборе входных параметров, поэтому качество обучения сети напрямую зависит от количества примеров в обучающей выборке, а также от того, насколько полно эти примеры описывают решаемую проблему.

Согласно теоретическим результатам [2, с. 5–6; 6, с. 9] и экспериментальному опыту, нейронные сети с прямой связью и с *S*-образной функцией активации являются универсальным средством для аппроксимации функций. Сети с прямой связью действительно могут служить универсальным средством для прогнозирования динамики цен на сталь, а технологии пакета STATISTICA Neural Networks позволяют осуществить автоматизированный поиск оптимальной топологии сети для конкретной задачи. Теоретически архитектура сети может быть произвольной, однако фактически она ограничена ресурсами компьютера, на котором реализуется создание нейронной сети. Следует отметить, однако, что чем сложнее нейронная сеть, тем масштабнее задачи, подвластные ей.

СПИСОК ЛИТЕРАТУРЫ

1. [http:// shipbuilding.ru](http://shipbuilding.ru).
2. Эстенс Д.-Э., Ван ден Берг В., Вуд Д. Нейронные сети и финансовые рынки: принятие решений в торговых операциях. – М.: ТВП, 1997. – 236 с.
3. Галушкин А. И. Нейронные сети: основы теории. – М.: Горячая Линия. – Телеком, 2010. – 496 с.
4. Петерс Э. Хаос и порядок на рынках капитала. Новый аналитический взгляд на циклы, цены и изменчивость рынка. – М.: Мир, 2000. – 333 с.
5. Тихонов Э. Е. Методы прогнозирования в условиях рынка: учеб. пособие. Северо-Кавказ. гос. техн. ун-т. – Невинномысск, 2006. – 221 с.
6. Расчет показателя Херста с целью выявления трендовости (персистентности) финансовых рынков. [Электронный ресурс] – Режим доступа: <http://capital-times.com.ua>.
7. Прогнозирование на основе нейронных сетей. [Электронный ресурс] – Режим доступа: <http://elanina.narod.ru>.
8. Яхьяева Г. Э. Нечеткие множества и нейронные сети: учеб. пособие. – М.: Интернет-Университет Информационных Технологий; БИНОМ. Лаборатория знаний, 2006. – 316 с.
9. Введение в искусственные нейронные сети. [Электронный ресурс] – Режим доступа: <http://neuroschool.narod.ru>.
10. Медведев В. С., Потемкин В. Г. Нейронные сети. MATLAB 6. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.

Статья поступила в редакцию 12.08.2011

ИНФОРМАЦИЯ ОБ АВТОРАХ

Виноградова Светлана Сергеевна – Астраханский государственный технический университет; ассистент кафедры «Экономика бизнеса и финансы»; тел.: 8 (8512) 614-125.

Vinogradova Svetlana Sergeevna – Astrakhan State Technical University; Assistant of the Department "Business Economics and Finance"; tel. 8 (8512) 614-125.

Касимов Николай Николаевич – Астраханский государственный технический университет; аспирант кафедры «Судостроение и энергетические комплексы морской техники»; тел.: 8 (8512) 614-166.

Kasimov Nickolay Nickolaevich – Astrakhan State Technical University; Postgraduate Student of the Department "Shipbuilding and Energetic Complexes of Sea Technological Equipment"; tel. 8 (8512) 614-166.