

Интеллектуальные и управляющие системы

В.С. Тормозов
аспирант

(Тихоокеанский государственный университет)
г. Хабаровск, Российская Федерация

Е.А. Кулпейс
докторант

К.К. Смагулова
доцент

(Карагандинский технический университет)
г. Караганда, Казахстан

Э.Ф. Амирова
доцент

(Казанский государственный аграрный университет)
г. Казань, Российская Федерация

П.К. Коротков
преподаватель

(Колледж сервиса и дизайна при Владивостокском университете
экономики и сервиса)

г. Владивосток, Российская Федерация

М.Р. Богданов
доцент

(Московский политехнический университет)

С.В. Выговский
студент

(Московский государственный технический университет им.
Н.Э. Баумана)

г. Москва, Российская Федерация

Метод автоматизированного краткосрочного прогнозирования временного ряда в онлайн-режиме

В статье рассматривается разработка программной системы информирования и прогнозирования временного ряда на примере курса валют на фондовой бирже Forex с применением математического аппарата искусственных нейронных сетей. Проблема прогнозирования будущих значений характеристик сложной системы была и остается на сегодняшний день актуальной. Наряду с традиционными методами прогнозирования временных рядов на сегодняшний день активно используется теория искусственных нейронных сетей, которая хорошо зарекомендовала себя в области управления, там где раньше было необходимо применение человеческого интеллекта, в частности при решении задач прогнозирования. С помощью модели прогнозирования значений валютных котировок можно делать достаточно достоверные краткосрочные прогнозы. Для большинства примеров выборки для тестирования прогноз показал правильное направление краткосрочного изменения исследуемой котировки. С помощью построенной модели прогнозирования можно делать достаточно достоверные краткосрочные прогнозы.

Ключевые слова: программная система; прогнозирование; временной ряд; Forex; валютные котировки.

V.S. Tormozov

Postgraduate Student

(Pacific State University)

Khabarovsk, Russian Federation

E.A. Kulpeys

Doctoral Student

K.K. Smagulova

Associate Professor

(Karaganda Technical University)

Karaganda, Kazakhstan

E.F. Amirova

Associate Professor

Kazan State Agrarian University

Kazan, Russian Federation

P.K. Korotkov

Teacher

(College of Service and Design at the Vladivostok University of
Economics and Service)

Vladivostok, Russian Federation

M.R. Bogdanov

Associate Professor

S.V. Vygovskiy

Student

(Bauman Moscow State Technical University)

Moscow, Russian Federation

Method of Automated Short-term Forecasting of Time Series in Online Mode

The article considers the development of a software system for informing and forecasting the time series, using the example of the exchange rate on the Forex stock exchange using a mathematical apparatus of artificial neural networks. The problem of predicting future values of the characteristics of a complex system has been and remains today. Along with traditional methods for predicting time series, the theory of artificial neural networks is currently actively used, which has proven itself in the field of control, where the use of human intelligence was previously necessary, in particular in solving prediction problems. Using the currency quotation value prediction model, you can make fairly reliable short-term forecasts. For most sample samples for testing, the forecast showed the correct direction of short-term change in the study quotation. Using the currency quotation value prediction model, you can make fairly reliable short-term forecasts. For most sample samples for testing, the forecast showed the correct direction of short-term change in the study quotation. With the help of the constructed forecasting model, you can make fairly reliable short-term forecasts.

Keywords: software system; forecasting; time series, Forex; currency quotes.

DOI: 10.25791/asu.7.2021.1296

Задача прогнозирования будущих значений временного ряда, полученного от наблюдения сложной системы, была и остается на сегодняшний день актуальной и окончательно не решенной. Большой научный интерес представляют формализованные задачи прогнозирования временных рядов различной природы: погоды по результатам соответствующих атмосферных измерений, характеристики окружающей среды, протекания экономических процессов, выведение новых видов растений и животных, детализация поведения индивидуумов в определенных сферах путем проведения соответствующего набора контрольных оценочных заданий. Особую роль прогнозирование играет в сферах экономики, финансов и коммерции: прогнозирование курса акций, динамики цен на товары, экономических показателей.

Наряду с классическими подходами к прогнозированию значений временных рядов бурно развиваются методы, построенные на математическом аппарате искусственных нейронных сетей (ИНС). Такой аппарат хорошо зарекомендовал себя в тех областях, где применяется умственный человеческий труд, в частности при решении задач прогнозирования [1].

Решения задачи прогнозирования значений временных рядов включают в себя достижения таких наук, как информатика, математика, нейробиология. Научный интерес к ИНС был вызван как теоретическими достижениями, так и достижениями в области решения прикладных задач [2...4]. Нейросетевые модели стали использоваться в научных направлениях, ранее относящихся лишь к области человеческого интеллекта.

Нейросетевая модель как система состоит из элементов – искусственных нейронов (ИН), функциональные возможности которых отдаленно подобны большинству элементарных функций биологического нейрона. В системах типичный ИН собирает сигналы от других через множество слоев подобных ему нейронов. Нейрон принимает суммарный сигнал, получаемый от всех нейронов предыдущего слоя. Функция активации, зависящая от типа нейрона, преобразует суммарный сигнал, который затем поступает либо на выходы ИНС, либо на следующий слой. Такая структура для точной работы

нуждается в настройке на примерах – обучении, путем изменения действия сигналов на каждый ИН.

ИНС могут быть представлены математическими моделями, а также программными или аппаратными реализациями моделей [5]. ИНС обладают способностью изменения своего ответа на входные сигналы с помощью процедуры машинного обучения [6]. Обучение для сети заключается в адаптации сети для обеспечения требуемой реакции: предъявляются входные сигналы и требуемые выходные сигналы. Обучение выполняется на опытных образцах: выполняется обобщение параметров опытных образцов на необходимый ответ при поступлении ранее не предъявленных примеров; извлечение наиболее характеризующих параметров примеров среди избыточных и разнородных данных. После поступления входных сигналов, весовые коэффициенты ИНС изменяются на основе вычисленной разницы векторов выходного сигнала и сигнала, обеспечивающего требуемый ответ системы.

Существует ряд архитектур ИНС и алгоритмов машинного обучения со своими особенностями и вследствие этого – сферой решаемых задач [7].

Все еще существует проблема, заключающаяся в неочевидности подбора оптимальной структуры и характеристик ИНС, классификационного состава и размеров выборок обучения и тестирования относительно условий решаемой задачи [8]. На сегодняшний момент проблема отражает актуальность работы.

Постановка задачи

Требуется реализовать и исследовать программную систему информирования и прогнозирования валютных котировок *Forex*. Через каждые три минуты система выполняет следующие операции:

- Значения текущих валютных котировок на фондовой бирже *Forex* в режиме онлайн считываются с интернет ресурса [9] и заносятся в предварительно спроектированную локальную базу данных (БД) – выполняется замер котировок.

- На основе ранее сохраненных данных о предыдущих значениях валютных котировок за последние двадцать замеров (час) выполняется операция краткосрочного прогнозирования следующих значений валютных котировок на следующий замер, прогнозируемые значения сохраняются в БД.

- Текущие и прогнозируемые значения котировок отображаются в онлайн-режиме, а также выводятся по запросу пользователя.

К обрабатываемым и прогнозируемым в системе валютным котировкам относятся: *EUR/AUD, EUR/CAD, EUR/CHF, EUR/GBP, EUR/JPY, EUR/USD, AUD/USD, CAD/JPY, CHF/JPY, GBP/CHF, GBP/JPY, GBP/USD, USD/CAD, USD/CHF*.

Описание используемой модели

Для увеличения чувствительности ИНС требуется сократить диапазон входных и выходных сигналов. Поэтому над входными и прогнозируемыми данными выполняется операция нормализации: нормализуются изменения значений котировок за период между двумя замерами котировок $T_{\text{прогноз}} = 180$ с.

Процедура обучения ИНС работает в течение более длительного временного интервала, чем прогнозирование, поэтому обучение выполняется реже, чем прогнозирование: $T_{\text{обучен}} = nT_{\text{прогноз}}$; $n = 20$.

Во избежание непроизводительной приостановки процедуры прогнозирования, машинное обучение выполняется в фоновом режиме. Подбор архитектуры и параметров ИНС производился на базе существующих эвристик. В течение запуска и работы программного комплекса параметры сети остаются постоянными. Параметрами ИНС являются: скорость обучения η и коэффициент функции активации α . Скорость обучения характеризует скорость, с которой погрешность работы ИНС уменьшается с увеличением количества пройденных итераций. Состояние нейрона в сети вычисляется по формуле:

$$S_j = \sum_{i=1}^N w_{ij} x_i,$$

где: S_j – состояние j -го нейрона;
 w_{ij} – весовой коэффициент связи i -го нейрона предыдущего слоя и j -го нейрона текущего слоя;
 x_i – значение сигнала от i -го нейрона предыдущего слоя.

Выход нейрона в сети определяется по формуле:

$$y = f(S) = \frac{1}{1 + e^{-\alpha S}},$$

где: y – выход нейрона;
 f – функция активации нейрона;
 S – состояние нейрона;
 α – коэффициент функции активации.

Обучение нейронной сети производится по алгоритму обратного распространения ошибки. Данный

алгоритм является одним из наиболее распространенных методов проведения корректировки весовых коэффициентов. Распространенность применения этого алгоритма определяется тем, что существует теоретическое доказательство сходимости процесса обучения по этому алгоритму. Обучение алгоритмом обратного распространения ошибки выполняется в два этапа по всем нейронным слоям: прямое распространение и обратное распространение.

При прямом распространении на входной слой нейронной сети подается вектор входных сигналов, после чего распространяется по сети от слоя к слою. В результате генерируется набор выходных сигналов, который и является реакцией сети на данный вектор входных сигналов. Во время прямого распространения все веса сети статические. Во время обратного прохождения сигнала весовые коэффициенты изменяются в соответствии с правилом коррекции погрешностей: фактический выходной вектор сети вычитается из требуемого вектора. Полученный вектор погрешностей сигналов впоследствии распространяется по сети в направлении, обратном направлению нейронных связей [10]. Весовые коэффициенты корректируются для максимального приближения выходного вектора сигналов сети к требуемому.

Сигмоидальная функция имеет область значений $E(f) = (0;1)$ [11]. Для корректного выполнения обучения алгоритмом обратного распространения ошибки необходимым условием является дифференцируемость активационной функции на всей области определения. Помимо того, что сигмоидальная функция удовлетворяет этому условию, выполняется автоматический контроль корректировки весовых коэффициентов. Для сигналов, значение которых близко к нулю, кривая вход-выход обладает более кривым наклоном, увеличивающим корректировочные значения весовых коэффициентов. При увеличении величины сигнала – корректировочные значения, наоборот, уменьшаются.

Машинное обучение ИНС алгоритмом обратного распространения ошибки является такая корректировка ее весов, которая позволяет разделить классы входных векторов на заданные множества выходных векторов [12]. Для каждого входного вектора сигналов задается ему целевой вектор. Совокупность входного и выходного вектора сигналов – обучающая пара. Машинное обучение ИНС выполняется на множествах пар.

Алгоритм обратного распространения ошибки состоит из последовательности выполняемых этапов [13]:

Шаг 1. Инициализация весовых коэффициентов близкими к нулю случайными значениями: $w_{ij} = rand(10^{-4}, \Delta I_{\text{max}})$.

Шаг 2. Извлечение обучающего примера из обучающей выборки; поступление входного вектора на вход ИНС.

Шаг 3. Поочередное вычисление выходных значений каждого слоя, значений выходного вектора ИНС.

Шаг 4. Вычисление абсолютного значения разности между целевым вектором обучающего примера и выходным вектором ИНС.

Шаг 5. Корректировка весовых коэффициентов для минимизации итоговой погрешности сети по всей обучающей выборке.

Шаг 6. Повторение этапов со 2 по 4 для каждого примера обучающей выборки до достижения погрешности приемлемого уровня на обучающем множестве. В рассматриваемой работе погрешность ИНС определяется как среднее арифметическое значений выходного вектора.

Этапы 2, 3 формируют прямое распространение сигнала: сигнал распространяется по сети от входного слоя к выходному.

Шаги 3 и 4 формируют обратное распространение сигнала: вычисляемый корректировочный вектор погрешности распространяется послойно в обратном порядке по ИНС и применяется для корректировки весовых коэффициентов.

Предлагаемая нейросетевая структура

Для выполнения краткосрочного прогнозирования эвристическим путем была выбрана ИНС следующей послойной структуры (рис. 1):

1) входной слой (960 нейронов) – на слой поступает нормированный входной вектор, формируемый на основе данных о валютах за n предыдущих замеров;

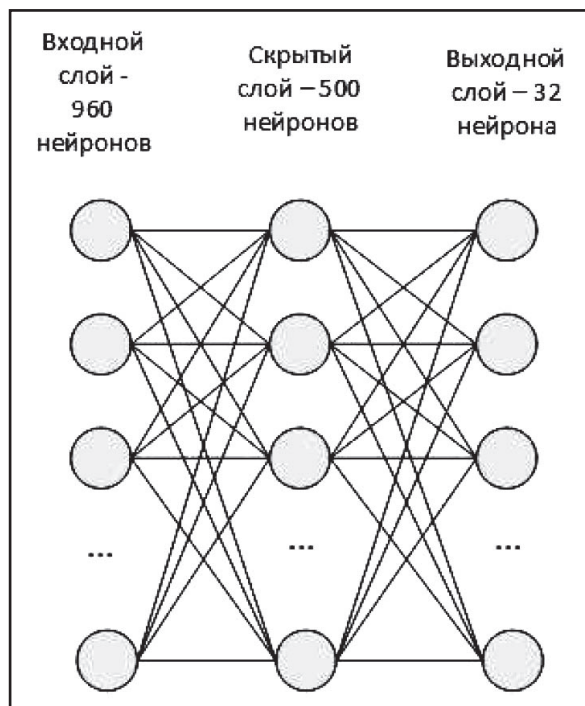


Рис. 1. Предлагаемая нейросетевая структура

2) один скрытый слой (500 нейронов) – извлекает низкоуровневые признаки ситуации, позволяющие выполнить ее оценку;

3) выходной слой (32 нейрона) — выходной вектор показывает спрогнозированные нормализованные приращения котировок.

Предварительная подготовка обучающей и контрольной выборок

После начала выполнения сервер прогнозирования ожидает получения входных данных по валютным котировкам – n замеров, достаточных для выполнения прогнозирования. После получения данных по котировкам n замеров, сервер прогнозирования запускает машинное обучение ИНС на основе полученных данных в потоке, параллельном основному. В это время основной поток периодически выполняет замеры котировок – извлекает значения из ресурса интернет, путем запроса и парсинга веб-страницы [9].

Во время работы машинного обучения ИНС прогнозирование не выполняется. После завершения очередной процедуры обучения, а также при достижении счетчика замеров n , минимального количества, достаточного для прогнозирования: $i_{\text{замер}} = n$, выполняется создание и начало работы потока прогнозирования. Результаты прогнозирования, полученные с помощью ИНС, заносятся в БД программной системы для применения сервером обработки запросов. Выполняется обнуление счетчика замеров $i_{\text{замер}} = 0$, происходит запуск потока обучения нейронной сети. Для того чтобы все значения входного вектора оказались в рамках допустимых значений элементов (для сигмоидальной функции это диапазон от нуля до единицы), исходные данные нужно предварительно подготовить. Выполняется нормализация исходных данных — изменения значений котировок приводятся к значениям в отрезке $[0, 1]$.

В результате анализа значительной выборки входных данных было обнаружено, что для абсолютной величины отклонения от среднего входных значений $\Delta I_{\text{норм}}(t) = |I_{\text{норм}}(t) - I_{\text{норм}}(t - T_{\text{прогноз}})|$ выполнимо: $\Delta I_{\text{норм}}(t) \leq \Delta I_{\text{max}}; \Delta I_{\text{max}} = 0.1$. Следовательно, входные сигналы образцов обучающей и тестирующей выборки принадлежат отрезку $[-\Delta I_{\text{max}}, \Delta I_{\text{max}}]$. Нормализация входных сигналов производится по следующей формуле [11]:

$$I_{2k+r} = \frac{d_{kr} + d_{\min}}{d_{\max} - d_{\min}},$$

где I_{2k+r} – нормализованное значение входного вектора для обучения;

d_{kr} – приращение значения k -ой характеристики на t -ом входном векторе;

$[d_{\min}, d_{\max}]$ – интервал возможных нормализованных значений входных векторов.

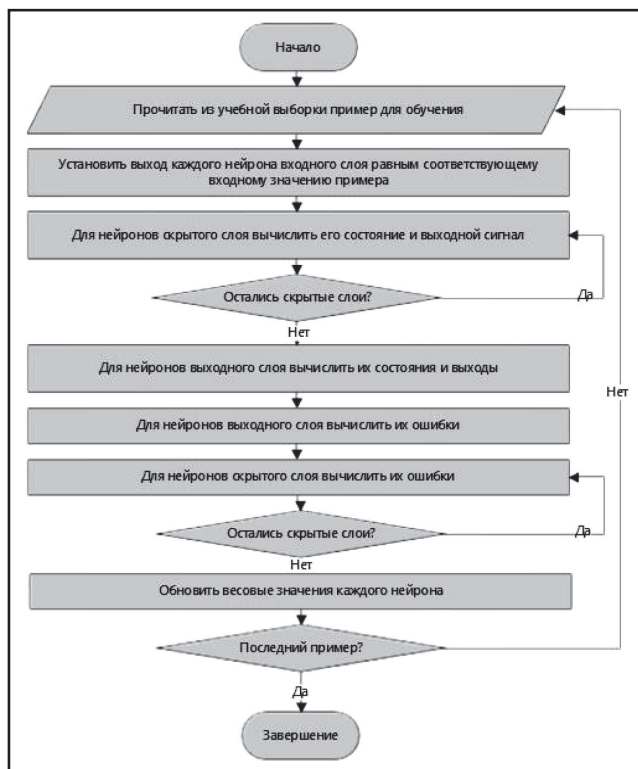


Рис. 2. Блок-схема алгоритма обучения ИНС

Настройка весовых коэффициентов ИНС выполняется по алгоритму обратного распространения ошибки. На каждой эпохе структуры данных корректируются на основе данных обучения, записанных в БД, затем выполняется проверка работы ИНС на множестве контрольных тестов. Условием завершения обучения является увеличение среднего значения погрешности, выдаваемой ИНС на всем множестве контрольных тестов. Средние арифметические значения погрешностей также заносятся в БД для контроля процессом обучения и администрирования. В итоге обученная ИНС применяется для прогнозирования котировок. Для этого входной вектор заполняется нормализованными изменениями котировок за последние n замеров. Входной вектор обрабатывается ИНС и содержит прогнозируемые нормализованные изменения котировок на следующий замер времени. Блок-схема алгоритма обучения ИНС отображена на рисунке 2.

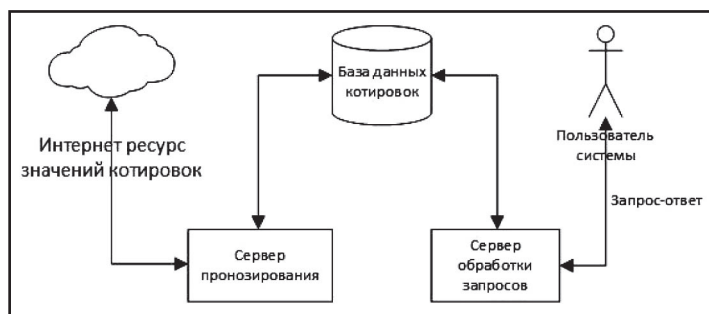


Рис. 3. Информационно-функциональная схема программной системы

Разработанная программная система

Программную систему можно обобщенно представить как систему, сформированную из трех базовых элементов [14]:

1. Компонента представления, реализующая интерфейс с пользователем системы. В работе к компоненте представления относятся: браузер и *Web-сервер Apache Tomcat* [15].

2. Прикладная компонента, выполняющая множество прикладных функций, необходимых для работы системы. Прикладная компонента представлена *jsp*-скриптами [16], выполняемыми *Web-сервером Apache Tomcat*.

3. Компонента доступа к данным, информационным ресурсам, являющимися носителями этих данных. Выполняет функции накопления и управления данными.

Для рассматриваемой программной системы средствами СУБД *PostgreSQL* [17] была спроектирована и создана БД. Для применения разработанной программной системы необходимо, чтобы одновременно выполнялись сервер обработки запросов и сервер прогнозирования. Эксплуатация программной системы состоит из последовательности этапов, представленных в таблице.

Как видно из таблицы, продолжительность машинного обучения на разных выборках может быть различным. Это связано с тем, что условием завершения процедуры обучения принято событие увеличения средней погрешности ИНС на контрольной выборке. Если же увеличения не происходит, то программная система выполнит предварительно заданное количество эпох обучения $n_{обуч}$ и успешно завершит весь цикл обучения. В ходе проведенных экспериментов по оптимизации машинного обучения, было выявлено наилучшее для этих целей значение $n_{обуч} = 10^5$.

Запуск сервера обработки запросов происходит параллельно с началом выполнения сервера *Apache Tomcat*. Запуск сервера прогнозирования выполняется с использованием командной строки: пользователем вводится строка «./имя_файла», «имя_файла» – имя исполняемого файла программы. После осуществления администратором активации сервера *Apache Tomcat*, пользователи могут просматривать прогнозируемые и текущие валютные котировки, осуществляя ввод в поле для *url*-браузера клиента: «адрес_сервера/index.jsp», «адрес_сервера» – интернет-адрес или *IP*-адрес сервера обработки запросов.

Информационно-функциональная схема программной системы (рис. 3) представляет комплексное представление об базовых элементах реализации каждого конкретного функционального процесса. Схема позволяет рассмотреть, на какие элементы информационной базы опирается реализация отдельных функций, источник данных, пользователей. Программная система составлена из трех базовых

Последовательность этапов эксплуатации программной системы

№	Выполняемый этап и решаемые задачи	Рекомендуемая продолжительность этапа, с
1	Инициализация начала выполнения серверов прогнозирования и обработки запросов.	1–5
2	Сбор данных из интернета сервером прогнозирования и запись полученных данных в БД, прогнозирование не выполняется. При соответствующем запросе сервер обработки запросов выполняет выдачу данных о текущих котировках.	60–600
3	Сервер собрал достаточно данных для начала обучения ИНС. Выполняется машинное обучение по прошлым замерам из БД. Обучение инициируется в отдельном программном потоке, одновременно с ним выполняется сбор данных из этапа 2. Продолжительность машинного обучения находится в зависимости от объемов обучающей и контрольной выборок, способности ИНС к обучению на этих выборках.	60–300
4	Инициализация начала выполнения прогнозирования на базе ранее обученной ИНС.	1–5
5	Процесс прогнозирования: выполняется инициализация машинного обучения в отдельном потоке. Сервер обработки запросов выдает значения текущих и прогнозируемых котировок валют.	3–5400
6	По запросу от пользователя успешно завершают работу сервер обработки запросов и сервер прогнозирования.	1–3

компонентов: сервера обработки запросов; сервера прогнозирования; базы данных котировок.

Сервер прогнозирования с заранее заданной периодичностью извлекает актуальные значения валютных котировок из онлайн-ресурса [9], выполняет сохранение в БД *PostgreSQL* (рис. 4).

При достижении объема записей значений валют в БД предельного значения, достаточного для проведения обучения ИНС, автоматически выполняется запуск машинного обучения. Исходя из того, что входными значениями модуля прогнозирования являются полученные от предыдущих замеров значения котировок валют, система изначально должна собрать достаточный объем данных о котировках, как минимум, за тридцать один замер. Указанное количество необходимо для построения только одного примера обучающей

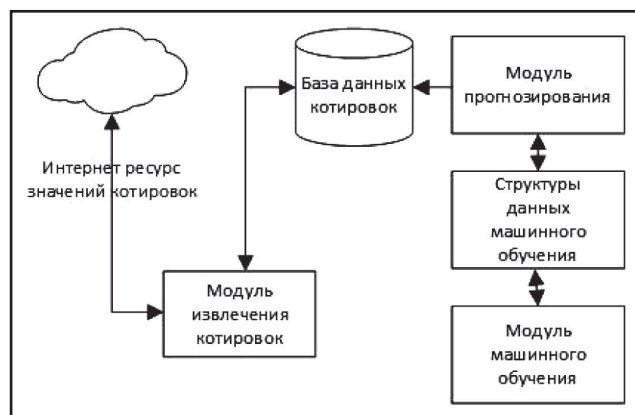


Рис. 4. Информационно-функциональная схема работы сервера прогнозирования

выборки. Обучение ИНС выполняется в отдельном потоке, благодаря чему параллельно с ним выполняется периодический замер котировок. Программная система запускает краткосрочное прогнозирование только после окончания машинного обучения.

Сервер обработки запросов выполнен в виде программы *java*, запускаемой и выполняющейся с помощью *JVM* и сервера *Apache Tomcat*. По запросу от пользователя программа выполняет отображение таблицы с данными о текущих и прогнозируемых котировках (рис. 5).

Проведенные эксперименты и полученные результаты

Целью проведения экспериментов является выявление возможных взаимных корреляций между разными парами котировок во времени на изучаемом периоде. В ходе экспериментов произведено построение и настройка ИНС с рассматриваемыми параметрами архитектуры. Размер и типы значений входного вектора заданы значениями торговой сессии биржи, получаемые за 30 замеров системы (960 входных нормированных значений). Выход сети задан требованиями к серверу прогнозирования: изменения цен покупки и продажи валютной пары; количество скрытых слоев – один, количество нейронов в скрытом слое 500.

Созданная ИНС была обучена на открытых данных временного ряда биржевых котировок *Forex* за период с 18 февраля 2018 по 31 мая 2018 [10]. Обучающая и контрольная выборки были разделены в отношении 7:1. Машинное обучение выполняется многократным

КУРС ВАЛЮТ				
Котировка	Сейчас		Через 3 минуты	
	Bid	Ask	Bid	Ask
AUD/JPY	79.48	79.51	79.55883	79.58846
AUD/USD	1.0069	1.0071	1.0875381	1.08776
CAD/JPY	76.87	76.9	76.94919	76.979195
CHF/JPY	82.76	82.79	82.83919	82.869194
EUR/AUD	1.2504	1.2509	1.3310889	1.3315983
EUR/CAD	1.2928	1.2933	1.3734865	1.3739841
EUR/CHF	1.201	1.2012	1.2816799	1.2818837
EUR/GBP	0.8048	0.805	0.88545966	0.8856604
EUR/JPY	99.41	99.43	99.48882	99.50882
EUR/USD	1.2592	1.2593	1.3398665	1.3399673
GBP/CHF	1.4919	1.4923	1.5726342	1.573012
GBP/JPY	123.48	123.52	123.561424	123.60142
GBP/USD	1.5645	1.5646	1.6451995	1.6452837
USD/CAD	1.0266	1.0267	1.107314	1.1073945

Рис. 5. Пример результата обработки запроса от пользователя сервером обработки запроса




Рис. 6. Результаты краткосрочного прогнозирования валютной котировки EUR/USD на 15 контрольных примерах

повторением эпох обучения по всем обучающим примерам и расчетом погрешности сети на контрольной выборке. Использовалась скорость обучения $\alpha=0.9$ с активным нейронным смещением.

Полученные результаты эксперимента по 15 примерам контрольного множества в конце изучаемого периода изображены на рисунке 6. Реальные данные изменений котировок по примерам представлены графиком функции $EURUSD_{\text{факт}}$, данные, выдаваемые сервером прогнозирования, представлены графиком функции $EURUSD_{\text{прогн}}$.

Заключение

Спроектирована и разработана программная система, реализующая следующие функциональности: вывод на экран актуальных значений котировок валют в режиме онлайн; запись прошлых изменений валютных котировок в БД; краткосрочное прогнозирование значений котировок. Система предназначена для

информирования и прогнозирования валютных котировок на рынке *Forex* в режиме онлайн.

Выполненный анализ полученных результатов эксперимента прояснил, что отобранная и настроенная модель ИНС, а также разработанная программная система краткосрочного прогнозирования значений временного ряда, дает возможность производить достаточно точные краткосрочные прогнозы. В большинстве исследуемых примеров выборки – 61,82 %. Разработанная система верно спрогнозировала направление движения курса в краткосрочном масштабе для исследуемой котировки. Программная система выдает погрешности при прогнозировании изменения абсолютных значений вектора движения котировок. Однако система достаточно достоверно предсказывает направление вектора движения.

Работа выполнена при поддержке Минобрнауки РФ, дополнительное соглашение от 21.04.2020 № 075-02-2020-1529/1.

Список литературы

- Haykin S. *Neural networks and learning machines 3/E*. Pearson Education India, 2010.
- Dzhangarov A.I., Suleymanova M.A., Zolkin A.L. Face recognition methods // *I OP Conference Series: Materials Science and Engineering*. IOP Publishing, 2020. Vol. 862, no. 4, pp. 42–46.
- Круглов В.В., Борисов В.В. *Искусственные нейронные сети. Теория и практика*. 2-е издание. М.: Горячая линия-Телеком, 2002. 382 с.
- Bogdanov R., Bogdanov M., Kusin P. Fractal structures in weakly dissipative kam theory and related problems // *Journal of Mathematical Sciences*. 2013. Vol. 189, no. 2.
- Галанов А.Э., Селюкова Г.П. Нейронные сети и нейронные технологии // *Актуальные вопросы науки и хозяйства: новые вызовы и решения*. 2019. С. 399–405.
- Тормозов В.С. Анализ методов распознавания образов и машинного обучения для распознавания визуальных образов // *Информационные технологии XXI века*. 2019. С. 354–359.
- Амосов О.С. Фильтрация марковских последовательностей на основе байесовского, нейросетевого подходов и систем нечеткой логики при обработке навигационной информации // *Известия Российской академии наук. Теория и системы управления*. 2004, № 4. С. 61–69.
- Baasher A.A., Fakhr M.W. Forex trend classification using machine learning techniques // *Proceedings of the 11th WSEAS international conference on Applied computer science. World Scientific and Engineering Academy and Society (WSEAS)*. 2011. Vol. 1, no. 1, pp. 41–47.
- Финам.ru. *Экспорт котировок Forex, форекс Eur/Usd – прогноз пары, курс валют и котировки*.

- Электронный ресурс: <https://www.finam.ru/profile/forex/eur-usd/export/> (дата обращения: 10.04.2021).
- Тормозов В.С., Золкин А.Л., Василенко К.А. Структурная оптимизация перцептрона с помощью аппарата эволюционного моделирования для задачи прогнозирования значений временных рядов // *Промышленные АСУ и контроллеры*. 2020, № 8. С. 40–45.
 - Ezeafulukwe U.A., Darus M., Fadipe-Joseph O. On analytic properties of a sigmoid function // *Int. Journal of Mathematics and Computer Science*. 2018. Vol. 13, no. 2, pp. 171–178.
 - Каллан Р. *Основные концепции нейронных сетей*. Prentice Hall, 2001. 287 с.
 - Созыккин А. В. Обзор методов обучения глубоких нейронных сетей // *Вестник Южно-Уральского государственного университета. Серия: Вычислительная математика и информатика*. 2017. Т. 6, № 3.
 - Isah H., Abughofa T., Mahfuz S., Ajerla D., Zulkernine F., Khan S. A survey of distributed data stream processing frameworks // *IEEE Access*. 2019. Vol. 7, pp. 300–316.
 - Vukotic A., Goodwill J. *Apache Tomcat 7*. New York: Apress. 2011. 293 p.
 - Wojciechowski J. MVC model, struts framework and file upload issues in web applications based on J2EE platform // *Proceedings of the International Conference Modern Problems of Radio Engineering, Telecommunications and Computer Science, 2014*. IEEE, 2014, pp. 342–345.
 - Строков А.А., Ширяев В.Е., Ширяев М.Е. СУБД PostgreSQL и ее применение для разработки баз данных в АСУ специального назначения // *Актуальные проблемы инфотелекоммуникаций в науке и образовании* (АПИНО 2018). 2018. С. 565–570.
 - and economy: new challenges and solutions]. 2019, pp. 399–405.
 - Tormozov V.S. Analiz metodov raspoznavaniya obrazov i mashinnogo obucheniya dlya raspoznavaniya vizualnyh obrazov [Analysis of Pattern Recognition and Machine Learning Methods for Visual Pattern Recognition]. *Informacionnye tekhnologii XXI veka* [Information Technologies of the XXI Century]. 2019, pp. 354–359.
 - Amosov O.S. Filtraciya markovskih posledovatelnostry na osnove bajesovskogo, nejrosetevogo podhoda i sistem nechetkoy logiki pri obrabotke navigacionnoj informacii [Filtration of Markov sequences based on Bayesian, neural network approaches and fuzzy logic systems in the processing of navigational information]. *Izvestiya Rossiyskoy akademii nauk. Teoriya i sistemy upravleniya* [Izvestiya Rossiyskogo akademii nauk. Control theory and systems]. 2004, no. 4, pp. 61–69.
 - Baasher A.A., Fakhr M.W. Forex trend classification using machine learning techniques // *Proceedings of the 11th WSEAS international conference on Applied computer science. World Scientific and Engineering Academy and Society (WSEAS)*. 2011. Vol. 1, no. 1, pp. 41–47.
 - Finam.ru. *Ekspert kotirovok Forex, foreks Eur/Usd – prognoz pary, kurs valyut i kotirovki* [Export quotes Forex, Forex Eur / Usd - pair forecast, exchange rates and quotes]. Available at: <https://www.finam.ru/profile/forex/eur-usd/export/>. (10.04.2021).
 - Tormozov V.S., Zolkin A.L., Vasilenko K.A. Strukturnaya optimizaciya perseptrona s pomoshch'yu apparata evolyucionnogo modelirovaniya dlya zadachi prognozirovaniya znachenij vremennyh ryadov [Structural optimization of the perceptron using the apparatus of evolutionary modeling for the problem of predicting the values of time series]. *Promyshlennyye ASU i kontrolyery* [Industrial Automatic Control Systems and Controllers]. 2020, no. 8, pp. 40–45.
 - Ezeafulukwe U.A., Darus M., Fadipe-Joseph O. On analytic properties of a sigmoid function. *Int. Journal of Mathematics and Computer Science*. 2018. Vol. 13, no. 2, pp. 171–178.
 - Kallan R. *Osnovnyye koncepcii nejronnyh setey* [Basic concepts of neural networks]. Prentice Hall, 2001. 287 p.
 - Sozykin A.V. Obzor metodov obucheniya glubokih nejronnyh setey [Review of methods for teaching deep neural networks]. *Vestnik Yuzhno-Uralskogo gosudarstvennogo universiteta. Seriya: Vychislitel'naya matematika i informatika* [Bulletin of the South Ural State University. Series: Computational Mathematics and Informatics]. 2017. Vol. 6, no. 3.
 - Isah H., Abughofa T., Mahfuz S., Ajerla D., Zulkernine F., Khan S. A survey of distributed data stream processing frameworks. *IEEE Access*. 2019. Vol. 7, pp. 300–316.
 - Vukotic A., Goodwill J. *Apache Tomcat 7*. New York: Apress. 2011. 293 p.

References

- Haykin S. *Neural networks and learning machines 3/E*. Pearson Education India, 2010.
- Dzhangarov A.I., Suleymanova M.A., Zolkin A.L. Face recognition methods // *I OP Conference Series: Materials Science and Engineering*. IOP Publishing, 2020. Vol. 862, no. 4, pp. 42–46.
- Kruglov V. V., Borisov V.V. *Iskusstvennyye neyronnyye seti. Teoriya i praktika*. 2-e izdanie [Artificial neural networks. Theory and practice. 2nd edition.]. M.: Goryachaya liniya-Telekom [Moscow: Hotline-Telecom]. 2002. 382 p.
- Bogdanov R., Bogdanov M., Kusun P. Fractal structures in weakly dissipative kam theory and related problems. *Journal of Mathematical Sciences*. 2013. Vol. 189, no. 2.
- Galanov A. E., Selyukova G. P. Neyronnyye seti i neyronnyye tekhnologii [Neural networks and neural technologies]. *Aktualnyye voprosy nauki i hozyaystva: novyye vyzovy i resheniya* [Actual problems of science

16. Wojciechowski J. MVC model, struts framework and file upload issues in web applications based on J2EE platform. *Proceedings of the International Conference Modern Problems of Radio Engineering, Telecommunications and Computer Science, 2014*. IEEE, 2014, pp. 342–345.
17. Stokov A.A., SHiryayev V.E., SHiryayev M.E. SUBD PostgreSQL i ee primeneniye dlya razrabotki baz dannyh

v ASU specialnogo naznacheniya [PostgreSQL DBMS and its Application for the Development of Databases in Special-Purpose ACS]. *Aktualnye problemy informatsionnykh telekommunikatsiy v nauke i obrazovanii (APINO 2018)* [Actual Problems of Information Telecommunications in Science and Education (APINO 2018)]. 2018, pp. 565–570.

Информация об авторах

Тормозов Владимир Сергеевич, аспирант кафедры «Вычислительная техника», соискатель ученой степени кандидата технических наук, старший преподаватель кафедры «Программное обеспечение вычислительной техники и автоматизированных систем»

Федеральное государственное бюджетное образовательное учреждение высшего образования «Тихоокеанский государственный университет»
680054, Российская Федерация, г. Хабаровск, ул. Тихоокеанская, д. 136

Кулпейс Ербол Аманжолулы, докторант кафедры «Автоматизация производственных процессов»

Смагулова Каршига Канатовна, доцент кафедры «Автоматизация производственных процессов»
Карагандинский технический университет
680054, Казахстан, г. Караганда, проспект Н. Назарбаева, д. 136

Амирова Эльмира Фаилловна, доцент кафедры «Экономика и информационные технологии»

Федеральное государственное бюджетное образовательное учреждение высшего образования «Казанский государственный аграрный университет»
420015, Российская Федерация, Республика Татарстан, г. Казань, ул. К. Маркса, д. 65

Коротков Павел Константинович, преподаватель Колледж сервиса и дизайна при Владивостокском университете экономики и сервиса (ВГУЭС)

690092, Российская Федерация, г. Владивосток, ул. Добровольского, 20

Богданов Михаил Рифкатович, доцент Федеральное государственное бюджетное образовательное учреждение высшего образования «Московский политехнический университет»

107023, Российская Федерация, г. Москва, ул. Большая Семеновская, д. 38

Выговский Святослав Валентинович, студент Федеральное государственное бюджетное образовательное учреждение высшего образования «Московский государственный технический университет им. Н.Э. Баумана»

105005, Российская Федерация, г. Москва, ул. 2-я Бауманская, д. 5

Information about the authors

Tormozov Vladimir Sergeevich, Postgraduate Student of the Department «Computer Engineering», Applicant for Degree of the Scientific Degree of Candidate of Technical Sciences, Senior Lecturer of the Department of Computer Software and Automated Systems

Federal State Budgetary Institution of Higher Education «Pacific State University»
680054, Russian Federation, Khabarovsk, Tikhookeanskaya Str., 136

Kulpeys Erbol Amanzholyuly, Doctoral Student of the department «Automation of Production Processes»

Smagulova Karshiga Kanatovna, Associate Professor of the Department «Automation of Production Processes»
Karaganda Technical University
680054, Kazakhstan, Karaganda, N. Nazarbayev Avenue, 136

Amirova Elmira Failovna, Associate Professor of the Department of Economics and Information Technologies
Federal State Budgetary Educational Institution of Higher Education «Kazan State Agrarian University»

420015, Russian Federation, Republic of Tatarstan, Kazan, Str. K. Marx, 65

Korotkov Pavel Konstantinovich, Senior Lecturer
College of Service and Design at the Vladivostok University of Economics and Service

690092, Russian Federation, Vladivostok, Dobrovolskaya Str., 20

Bogdanov Mihail Rifkatovich, Associate Professor
Federal State Budgetary Educational Institution of Higher Education «Moscow Polytechnic University»

107023, Russian Federation, Moscow, Str. Bolshaya Semenovskaya, 38

Vygovskiy Svyatoslav Valentinovich, Student
Federal State Educational Institution of Higher Education «Bauman Moscow State Technical University»

105005, Russian Federation, Moscow, Str. 2nd Bauman, 5