



лить правильность реакции системы на формируемые внешние воздействия в виде изменения условий кредитования и параметров производства продукции на предприятиях. По итогам реализации модели формируются, во-первых, графики, отображающие изменения во времени таких показателей: внутренний валовый продукт, прибыль, валовые инвестиции, и, во-вторых, изображение на плоскости агентов предприятий и агентов банков с учетом их объема капитала и возникших взаимосвязей в процессе кредитования в виде финансовых потоков.

Таким образом, разрабатываемое программное обеспечение МСИМ процессом взаимодействия банковского и реального секторов на макроуровне позволяет проводить сценарные исследования взаимодействия агентов в виде банков с предприятиями при реализации различных инвестиционных решений.

### Литература

1. Шарп У.Ф., Александер Г.Дж., Бэйли Дж.В. Инвестиции – М.: Инфра-М, 2001. — 1028 с.
2. Виттих В. А. Мультиагентные модели взаимодействий для построения сетей потребностей и возможностей в открытых системах / В. А. Виттих, П. О. Скобелев // Автоматика и телемеханика. – 2003. - №1. – С. 177-185.
3. Карпов Ю. Имитационное моделирование систем. Введение в моделирование с AnyLogic 5. – СПб.: БХВ-Петербург, 2005. – 400с.
4. Исследование сценариев управления взаимодействием предприятий и банков на мезоуровне с использованием мультиагентных технологий / Е. А. Макарова, Т. А. Ефтонова, Р. Н. Булатова, В. Р. Гатиятуллина, // «Информационные технологии интеллектуальной поддержки принятия решений»: сб. науч. тр. III. междунар. конф., Уфа: УГАТУ, 2015г. Т. 2. С.205-210.
5. Макаров В. Л., Бахтизин А. Р. Социальное моделирование — новый компьютерный прорыв (агент-ориентированные модели). — Экономика М, 2013. — С. 295.

Д.А. Воробьев, В.Г. Литвинов

## АВТОМАТИЗИРОВАННАЯ СИСТЕМА ПРОГНОЗИРОВАНИЯ ПОВЕДЕНИЯ ВАЛЮТНОГО РЫНКА С ПРИМЕНЕНИЕМ АНАЛИЗА ЭМОЦИОНАЛЬНОЙ ОКРАСКИ СООБЩЕНИЙ В СОЦИАЛЬНЫХ СЕТЯХ

(Самарский университет)

Одной из наиболее востребованных задач валютного дилинга и технического анализа финансовых данных является прогнозирование. В том или ином виде с задачами прогнозирования люди сталкивались на всех исторических этапах существования цивилизации. Однако, до тех пор, пока в его основу не были положены научные подходы и методы, прогнозы составлялись на уровне интуиции, знаний и опыта людей. Успех на валютном, или фондовом рынке в значительной мере обусловлен точностью прогнозирования.



Пусть значения временного ряда доступны в дискретные моменты времени  $t = 1, 2, \dots, T$ . Обозначим временной ряд  $Z(t) = Z(1), Z(2), \dots, Z(T)$ . В момент времени  $T$  необходимо определить значения процесса  $Z(t)$  в моменты времени  $T+1, \dots, T+P$ . Момент времени  $T$  называется моментом прогноза, а величина  $P$  — временем упреждения [1].

Целью данной работы является разработка метода прогнозирования поведения валютного рынка, при котором можно сделать наиболее точный прогноз, основываясь на имеющихся данных. Решение задачи прогнозирования может быть выполнено различными методами, такими, как метод линейной регрессии, при помощи нейронных сетей, деревьев принятия решений (деревья прогнозирования и классификации). С точки зрения технологий анализа данных, прогнозирование может рассматриваться как определение некоторой неизвестной величины по набору связанных с ней значений.

Для решения задачи был обучен многослойный персептрон, позволяющий проследить влияние внешних факторов на курсы валют.

Одним из факторов, оказывающих влияние на колебание стоимости валют является стоимость товарных рынков. Было проведено исследование, позволяющее предсказать изменение стоимости евро относительно американского доллара.

В качестве алгоритма обучения многослойного персептрона использован алгоритм стохастического градиентного спуска [2, 3]. Исходные данные были поделены на обучающую и тестируемую выборку в соотношении 4:1.

Математически, искусственный нейрон обычно представляют как некоторую нелинейную функцию от единственного аргумента — линейной комбинации всех входных сигналов. Данную функцию называют функцией активации или функцией срабатывания, передаточной функцией. Существует множество функций активации, таких как Линейная, Сигмоид (Логистическая), Гиперболический тангенс.

Для активации была выбрана функция «выпрямитель» (rectifier). Нейроны с данной функцией активации называются ReLU (rectified linear unit). Применение ReLU существенно повышает скорость сходимости стохастического градиентного спуска (в некоторых случаях до 6 раз [4]) по сравнению с сигмоидой и гиперболическим тангенсом. ReLU реализует простой пороговый переход в нуле и имеет следующую формулу:

$$f(x) = \max(0, x)$$

В настоящее время для решения задачи оптимизации параметров нейронных сетей разработано большое количество различных методов, таких как Nesterov Accelerated Gradient, AdaGrad, Adam, RMSProp и Adadelta [5]. Обновление весов нейронной сети происходит посредством применения итерационного метода обратного распространения ошибки [2, 3]. В качестве метода оптимизации использован Adam, так как он показывает наибольшую скорость сходимости по сравнению с другими методами. В качестве сравнения эффективности были использованы показатели среднеквадратичного отклонения (СКО) для тестируемой выборки.



На графике 1 представлено значение СКО на логарифмической шкале на различных эпохах обучения. Среднее значение СКО в серии измерений составило  $1,2508 * 10^{-4}$ .

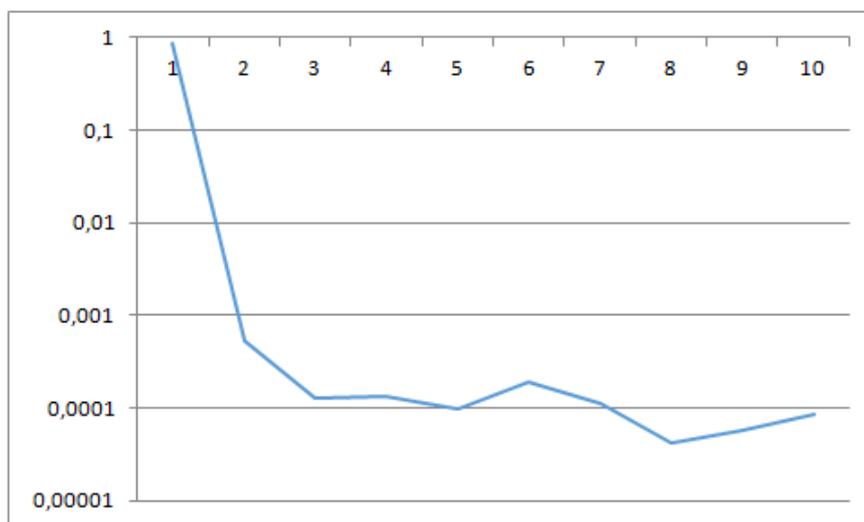


Рис. 1. Значение СКО на этапе обучения

Было сделано предположение о влиянии социальных оценок на финансовый рынок. Для изучения этого факторы были собраны данные из социальной сети Twitter за период с июля 2016 года по август 2017. Для того, чтобы осуществить сбор данных, на кластере Королёв был развернут сервер Ambari, который с помощью инструмента Apache Flume собирал данные по ключевым словам. Данные сохранялись в распределенную базу данных Hadoop на сервере Ambari.

Чтобы иметь возможность использовать эти данные для обучения нейронной сети, была проведена работа по обработке данных. Из каждой сохраненной записи твиттера был извлечен текст и проведен анализ тональности. Тональность каждой записи была представлена числом в диапазоне между нулем и единицей.

Для проведения анализа была использована библиотека TextBlob на языке Python, использующая в своем решении Наивный Байесовский классификатор. Наивный Байесовский классификатор – это широкий класс алгоритмов классификации, основанный на принципе максимума апостериорной вероятности.

В процессе анализа была получена тональность сообщений твиттера, которая затем была сгруппирована и усреднена.

Анализ влияния эмоциональной окраски сообщений на поведение валютного рынка был проведен с использованием многослойного персептрона. Сеть была обучена по аналогии с первым экспериментом, однако помимо стоимости драгоценных металлов обучающая выборка содержала подготовленные данные из социальной сети Twitter.



На графике 2 представлено значение СКО на логарифмической шкале на различных эпохах обучения. Среднее значение СКО в серии измерений составило  $4,408 \cdot 10^{-5}$ .

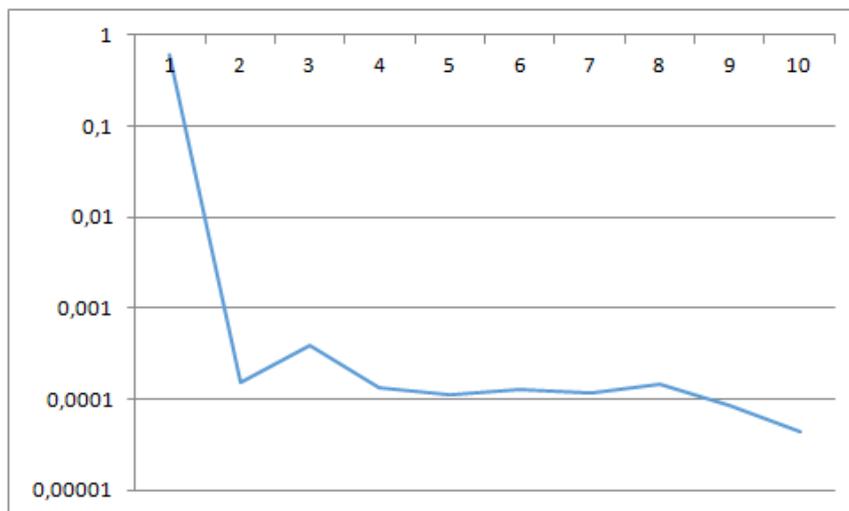


Рис. 2. Значение СКО на логарифмической шкале

Полученные результаты позволяют сделать вывод о том, что использование подготовленных данных из социальных сетей способно повысить точность прогнозирования. Однако, многослойный персептрон может давать значительно менее точные результаты, чем рекуррентные нейронные сети. Дальнейшее исследование будет направлено на нахождение оптимальной конфигурации сети и сравнение эффективности LSTM сети, персептрона и методов линейной регрессии для решения задачи прогнозирования.

### Литература

1. Бокс Г., Дженкинс Г. Анализ временных рядов: Прогноз и управление. – М.: Мир, 1974. 406 с.
2. Осовский, С. Нейронные сети для обработки информации [Текст] / С. Осовский // Учебно-справочное издание, – 2002.
3. Хайкин С. Нейронные сети: полный курс, 2-е издание. – Издательский дом Вильямс, 2008.
4. Krizhevsky A., Sutskever I., Hinton G. E. Imagenet classification with deep convolutional neural networks // Advances in neural information processing systems. – 2012. – С. 1097-1105.
5. Суша А.В. Анализ методов оптимизации параметров нейронных сетей на примере задачи классификации изображений // Студенческий: электрон. научн. журн. 2017. № 8(8). URL: <https://sibac.info/journal/student/8/79708> (дата обращения: 20.03.2018).