

УДК 004.93

Паначев Антон Анатольевич,

аспирант,
кафедра Анализа систем и принятия решений,
Высшая школа экономики и менеджмента,
ФГАОУ ВО «Уральский федеральный университет
имени первого Президента России Б.Н.Ельцина»
г.Екатеринбург, Российская Федерация

Тихоновская Ирина Дмитриевна,

аспирант,
кафедра Экономики и управления качеством продукции,
Высшая школа экономики и менеджмента,
ФГАОУ ВО «Уральский федеральный университет
имени первого Президента России Б.Н.Ельцина»
г.Екатеринбург, Российская Федерация

Комоцкий Евгений Игоревич,

магистрант,
департамент Бизнес-информатики и математического
моделирования,
Высшая школа экономики и менеджмента,
ФГАОУ ВО «Уральский федеральный университет
имени первого Президента России Б.Н.Ельцина»
г.Екатеринбург, Российская Федерация

**ПРИМЕНЕНИЕ НЕЙРОСЕТЕВОЙ МОДЕЛИ ДЛЯ
ПРОГНОЗИРОВАНИЯ ЦЕНЫ НА ЛОМ ЧЕРНЫХ
МЕТАЛЛОВ**

Аннотация:

В статье рассматривается проблема прогнозирования цен на рынке черной металлургии, что является важным фактором не только для планирования на предприятии, но и для обеспечения рыночной конкурентоспособности. Решение проблемы в данной работе достигается при помощи моделирования искусственных нейронных сетей. Полученная модель позволяет с высокой точностью прогнозировать изменение цен на рынке черных металлов. Данное исследование показывает, что нейронные сети представляют собой подходящий инструмент для прогнозирования волатильности цен на металлопродукцию.

Ключевые слова:

искусственные нейронные сети, цены на черную металлургию, машинное обучение, прогнозирование цен

Введение

Проблема прогнозирования цен закупки на черную металлургию сегодня существенным образом влияет на все сферы деятельности металлургического предприятия. В частности, при осуществлении хозяйственного планирования на предприятии, планово-экономический отдел закладывает определенные весовые факторы и ценовые параметры, волатильность которых существенным образом влияет на итоговый результат деятельности. Цена на лом – важнейший фактор, фигурирующий на всех уровнях планирования, начиная с материально-технического, где определяется потребность в сырье для дальнейшего проката, заканчивая коммерческим, где от себестоимости проката зависит фактическая цена сбыта. Стоит отметить, что ценовая волатильность на рынке черной металлургии влияет и на конечную конкурентоспособность предприятия-прокатчика. Например, при повышении затрат на покупку лома для дальнейшего проката, по сравнению с плановыми значениями, предприятие в конечном итоге будет вынуждено поднять цену конечного продукта из-за возросшей себестоимости, что наносит существенный ущерб конечной конкурентоспособности, так же может повлечь и отклонения в коммерческих планах предприятия, при неудачном сбыте конечного продукта. Справедлива и обратная ситуация, когда цена фактической закупки оказывается ниже плановой, в таком случае предприятие получает возможность снизить конечную стоимость, обеспечив себе тем самым улучшение конкурентного положения, а также увеличить объем выручки. В связи с описанной проблематикой, можно сделать вывод о необходимости минимизации отклонений фактических показателей от плановых, в частности цен на покупку лома для дальнейшего производства. Для данной задачи необходим инструмент, позволяющий прогнозировать уровень цен в перспективе, опираясь на данные предыдущих периодов.

На сегодняшний день к основным применяемым на предприятиях моделям прогнозирования можно отнести [4]:

- экспоненциальное среднее;
- модели Хольта;
- модель Хольта-Уинтерса;
- парная регрессия;
- множественная регрессия;
- системы эконометрических уравнений;

– модель Бокса-Дженкинса (ARIMA).

Однако, к наиболее современным и эффективным моделям прогнозирования относят:

- нейронные сети;
- имитационное моделирование.

Последние – используются редко, так как требуют от предприятия покупки дополнительного специализированного программного обеспечения.

Целью данной работы является построение модели прогнозирования цены на лом черных металлов. Моделью для анализа данных и построения выбраны искусственные нейронные сети (многослойный персептрон Розенблатта).

Методика

Для практической реализации задачи был выбран фреймворк Keras, в качестве Backend для данного продукта использовался Tensorflow.

В процессе работы осуществлялись изменения следующих гиперпараметров нейронной сети для достижения лучшего результата:

- Количество эпох обучения;
- Количество слоев и нейронов в слое.

Построение модели

Для прогнозирования цен на лом на российском рынке, а именно цен на металлолом вида 3А на внутреннем рынке СРТ руб./т без НДС (средневзвешенная по поставкам ж/д и автотранспортом) (Рмвн) первоначально были отобраны следующие предикторы внешней микросреды [6]:

Цена на арматуру на внутреннем рынке, 10-32 мм, А500С, СРТ, руб./т с НДС, (Равн);

Цена на металлолом экспортная, СРТ Ростов-на-Дону, руб./т, (Рмсрт);

Цена на переделный чугун, EXW руб./т с НДС, (Рпч);

Поставки металлолома на внутреннем рынке, тыс. т (ж/д и автотранспортом), (Вмвн);

Цена на квадратную заготовку на экспортном рынке, руб./т с НДС, (Цквзаг) [5];

Объем экспорта металлолома, тыс. т, (Вмэксп) [2];

Потребность в ломе на внутреннем рынке, тыс. т, (Впотрм);

Запасы лома на складах металлургических предприятий на начало месяца, тыс. т, (Взапм);

Цена на металлолом HMS 1/2 80:20, CFR Турция, \$/т, (Hmcftr) [7].

Также были отобраны следующие предикторы внешней мезо- и макросреды:

Курс доллара, руб./\$, (\$) [3];

Инфляция, п.п., (I) [3];

Ключевая ставка, п.п., (IR) [3].

Для построения модели выбраны следующие наборы данных:

– обучающий набор данных состоит из 60 записей (с 01.01.2011 по 01.12.2015);

– тренировочный набор данных состоит из 12 записей (с 01.01.2016 по 01.12.2016).

Процесс обработки данных

Используемый для задачи набор данных обладает небольшим размером обучающих примеров и малым числом переменных (с точки зрения методов нейронных сетей).

Указанный факт делал бессмысленным отбор переменных для нейронной сети.

В то же время данные используемые в процессе предсказания различались разным масштабом шкал, что могло негативно сказаться на работе нейронной сети с учетом малого числа обучающих примеров.

Для решения этой проблемы было необходимо выполнить нормализацию данных.

В качестве способа нормализации был выбран метод Z-нормализации:

$$z = \frac{x - \text{mean}(x)}{\text{stdev}(x)}$$

Где:

X – текущее значение переменной для обучающего примера;

mean(x) – среднее значение для переменной (рассчитывается для каждой переменной отдельно);

stdev(x) – стандартное отклонение для переменной (рассчитывается для каждой переменной отдельно);

Число итераций (эпох) обучения было установлено в 5000 в процессе выбора топологии сети и не изменялось.

В качестве базового алгоритма оптимизации был выбран ADAM [1], данный алгоритм так же не изменялся в процессе выбора топологии.

В качестве функции потерь, подлежащей оптимизации была выбрана MSE, данная функция также не изменялась в процессе выбора топологии

В качестве метрики качества предсказания был выбран коэффициент детерминации (R2).

В таблице ниже представлены результаты моделирования для различных топологий сети.

Имя каждой записи кодирует топологию следующим образом: метод оптимизации_N нейронов в слое.

Таблица 1 – Влияние топологии сети на предсказательную силу модели

Экземпляр топологии	R2 для обучающей выборки	R2 для тестовой выборки
ADAM_40	0.183	0.734
ADAM_80	0.234	0.642
ADAM_120	0.362	0.608
ADAM_40_20	0.974	0.426
ADAM_80_40	0.998	0.757
ADAM_120_80	0.999	0.735

Таким образом, были получены следующие результаты:

При увеличении числа нейронов в случае однослойной сети происходит улучшение точности для обучающей выборки, с одновременным ухудшением предсказательной силы модели

При увеличении числа слоев происходит резкое переобучение модели (о чем свидетельствует показатель R2 близкий к 1 для обучающей выборки), но при этом предсказательная сила оказывается хуже, чем в случае с однослойной топологией

В результате, было принято решение исследовать влияние такого метапараметра, как число эпох обучения для топологий ADAM_40, ADAM_40_20 и ADAM_80_40.

В данном эксперименте алгоритм оптимизации, функция потерь и метрика качества остались без изменений относительно предыдущего эксперимента (ADAM, MSE и R2 соответственно).

Изменению подлежало лишь число эпох обучения для выбранных топологий.

Результаты моделирования для различного числа эпох обучения представлены в Таблице 2.

Имя каждой записи кодирует топологию и число эпох обучения следующим образом: метод оптимизации_N нейронов в слое_число эпох обучения

Таблица 2 – Влияние числа эпох обучения на предсказательную силу модели.

Экземпляр топологии	R2 для обучающей выборки	R2 для тестовой выборки
ADAM_40_5000	0.183	0.734
ADAM_40_7500	0.343	0.619
ADAM_40_10000	0.469	0.466
ADAM_40_20_5000	0.974	0.426
ADAM_40_20_7500	0.999	0.780
ADAM_40_20_10000	0.999	0.788
ADAM_80_40_5000	0.998	0.757
ADAM_80_40_7500	0.999	0.765
ADAM_80_40_10000	0.999	0.765

Проведенный эксперимент позволяет сделать следующие выводы:

- Увеличение числа эпох ведет к переобучению модели для простых топологий с одновременным ухудшением предсказательной силы модели
- В случае сложных топологий увеличение числа эпох приводит к незначительному улучшению предсказательной силы модели.

Полученная корреляция в графическом выражении представлена на рисунке 1:




Рисунок 1. Корреляция между фактической ценой на лом вида 3А и рассчитанной при помощи искусственной нейронной сети (ИНС).

В результате проведенного исследования, можно сделать вывод, что наилучшую предсказательную силу показала модель со следующими метопараметрами:

Алгоритм оптимизации - ADAM

Функция потерь – MSE

Число эпох – 10 000

Тип топологии – двухслойная

Число выходных переменных – 15 (см. п. 1)

Число нейронов входного слоя – 40

Число нейронов скрытого слоя – 20

Число нейронов выходного слоя – 1

С помощью указанной модели удалось достичь показателя R^2 в 0,99 и 0,79 для обучающей и тестовой выборки соответственно, что безусловно демонстрирует хорошую связь. Однако значение коэффициента детерминации далеко от показателя, равного 1, что говорит об отсутствии точного соотношения между фактическими ценами на лом черных металлов и ценами, рассчитанными при помощи модели искусственных нейронных сетей.

Список используемых источников

1. Kingma D. P. , Lei Ba J. Adam: a method for stochastic optimization. 21.10.2017 <https://arxiv.org/pdf/1412.6980.pdf>
2. Металл-Эксперт URL: <http://metalexpert.com/ru/index.html> 22.10.2017
3. Центральный банк Российской Федерации URL:http://cbr.ru/currency_base 22.10.2017
4. Косовцева Т.Р., Беляев В.В. Технологии обработки экономической информации. Адаптивные методы прогнозирования. Учебное пособие. – СПб: Университет ИТМО, 2016.
5. Лондонская биржа металлов (London Metal Exchange) URL: <http://www.lme.com> 22.10.2017
6. Денисенко М. Палицын В. Особенности прогнозирования цен на продукцию предприятий черной металлургии // Национальная металлургия, №5, 2003.
7. Steel Statistical Yearbook 2012. World Steel Association. – Brussels, Belgium, 2012.

Panachev Anton,

Graduate student,
Department of Systems Analysis and Decision-making,
Graduate School of Economics and Management,
Ural Federal University
named after the first President of Russia B.N. Yeltsin
Ekaterinburg, Russian Federation

Tikhonovskaya Irina,

Graduate student,
Department of Economics and Quality Management
Graduate School of Economics and Management,
Ural Federal University
named after the first President of Russia B.N. Yeltsin
Ekaterinburg, Russian Federation

Komotskiy Evgeny,

Master student,
Department of Business Informatics and Mathematical Modelling,
Graduate School of Economics and Management,
Ural Federal University
named after the first President of Russia B.N. Yeltsin
Ekaterinburg, Russian Federation

**APPLICATION OF NEURAL NETWORK MODEL TO
PREDICT THE PRICE OF FERROUS SCRAP**

Abstract:

In this article considers the problem of forecasting prices on the steel market, which is important factor not only for planning but also for market competitiveness. The solution in this work is achieved through simulation of artificial neural networks. The resulting model allows high accuracy to predict the price changes on the market of black metals. This study shows that neural networks is a suitable tool to predict the volatility of prices on sheet metal products.

Key words:

artificial neural network, prices for iron and steel industry, machine learning, price forecasting