

щая рыночный торг между производителями и потребителями сельхозпродукции в условиях прямого субсидирования производства со стороны государства.

Выполненный анализ показал, что различия в степени влияния государства на деятельность сельскохозяйственных производителей стимулирует некоторых участников рыночных отношений к расширению производства. Производители, которые имеют более высокие производственные издержки даже при государственной поддержке (субсидировании) производства в случае их «неудачного» пространственного расположения в условиях конкуренции, вынуждены снижать объемы производства и продажи сельскохозяйственной продукции на аграрном рынке. Начальные условия и степень рассредоточенности производителей в пространстве оказывают существенное воздействие на конечные экономические результаты деятельности самих производителей.

Библиографический список

1. Дмитриенко К.Ю. Моделирование оптимального поведения фирмы на рынке олигополии при условии неценовой дифференциации товара // Вестник НГУ. Серия: Социально-экономические науки. – 2009. – Т. 9. – Вып. 1. – 42 с.
2. Понькина Е.В., Захарова Ю.А. Модель рассредоточенного при асимметрии распределения транспортных расходов между агентами // Изв. Алт. гос. ун-та. – 2013. – №1(77). DOI 10.14258/izvasu(2013)1.2-18.
3. Понькина Е.В., Маничева А.С. Имитационное моделирование рассредоточенного, мультиагентного рынка зерна // Вестник НГУ. Серия: Информационные технологии. – 2010. – Т. 8. – Вып. 2. – 54 с.
4. Костюк К.И. Исследование эффектов субсидирования производства на товарном рынке при пространственной рассредоточенности участников // Изв. Алт. гос. ун-та. – 2019. – № 1 (105). DOI 10.14258/izvasu(2019)1-14.

УДК 330.4

Использование сверточной нейросети для прогнозирования курса акций

Д.А. Малимонов, Д.Ю. Козлов
АлтГУ, г. Барнаул

Для решения задач прогнозирования курса акций широкое распространение в последнее десятилетие получили искусственные нейронные сети. Их использование в сфере финансов обусловлено, в первую

очередь, способностью работать с зашумленными и противоречивыми данными [1–3].

Были получены исторические данные курса акций двух зарубежных (Tesla, Google) и двух российских компаний (Газпром, Сбербанк) за 5 летний период начиная с мая 2014 года и заканчивая маем 2019 года с периодичностью в 1 день. В датасетах содержатся переменные: цены акций в момент открытия и закрытия рынка, максимальная и минимальная цены, а также объемы торгов. К имеющимся 5 переменным было решено добавить стандартное отклонение за n дней (этот параметр варьировался при настройке нейросети), характеризующее волатильность курсов акций:

$$\text{volatility} = \sqrt{\frac{\sum_{i=1}^n (\text{Close}_i - \text{Close}_{i-1})^2}{n-1}},$$

где Close – цена закрытия. Все данные нормировались, и поэтому переменные имели значения в интервале от 0 до 1.

Данное исследование направленно на поиск паттернов для прогнозирования цены закрытия акций компаний, поэтому было решено использовать свёрточные нейросети, которые применяются для распознавания образов. Предполагается, что сеть будет находить паттерны и на их основании предсказывать дальнейшее движение цены. С такой задачей, скажем, нейросеть архитектуры многослойный перцептрон будет справляться гораздо хуже по причине того, что она не связывает входные данные (например, текущая цена не имела бы зависимости от предыдущей), что лишает ее возможности находить скрытые паттерны.

Далее вся выборка была разбита на обучаемую и тестируемую подвыборки в соотношении 90/10%. В качестве инструментов прогнозирования был выбран язык программирования Python и библиотека Keras. Средой разработки стал облачный Colaboratory от Google [4].

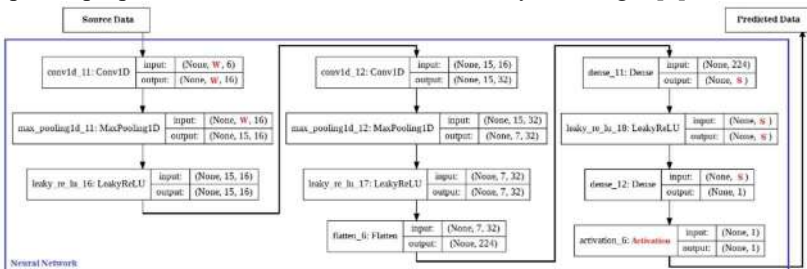


Рисунок 1 – Структура слоев построенной нейронной сети

Структура слоев предлагаемой нейронной сети представлена на рисунке 1. В ней 11 слоев: первая и вторая тройки слоев представляют из себя свертку “Conv1D” и объединение “MaxPooling1D” данных [5]. И в

первом, и во втором случае в конце стоит слой активации с функцией “LeakyReLU”. Эта функция обучает сети быстрее и с меньшим количеством потерь, так как на отрицательные значения, из-за своей специфики, она реагирует более отзывчиво, чем остальные функции. Седьмым идет слой сглаживания “Flatten”. Он предназначен для перевода двумерного массива данных в одномерный. Далее идут два полносвязных слоя “Dense”, входы и выходы которых соединены по принципу “каждый с каждым”. Между ними установлен еще один слой активации с функцией “LeakyReLU”. В конце стоит выходной слой активации, который и выдает прогнозные значения. Параметры слоев W, S и Activation (Рисунок 1), являются плавающими, и варьируются в ходе настройки нейронной сети.

Таблица 1 – Гиперпараметры нейросети для каждой акции.

Гиперпараметры	Tesla	Google	Газпром	Сбербанк
W (окно паттернов)	30	30	30	30
S (размерность выхода)	64	32	32	64
Функция потерь	MSE	MSE	MAE	MAE
Оптимизатор	Nadam	Adam	Adam	Nadam
Коэф. скорости обучения	0.001	0.002	0.002	0.002

Гиперпараметров компиляции модели также относительно большое количество, большинство из них определяются экспериментально, но для правильного подбора было решено воспользоваться поиском по решетке. Суть данного подхода заключается в прогонке сети по всем представленным вариантам параметров в течении малого количества эпох и дальнейшем выборе тех, при которых функция потерь показывает наилучший результат [6]. Итоги оптимизации гиперпараметров представлены в таблице 1.

Как можно заметить из таблицы 1 для каждой акции, при оптимизации, подбирается индивидуальный набор гиперпараметров, что свидетельствует о том, что “природа” каждой акции своеобразна и построить модель нейронной сети с универсальным набором параметров не представляется возможным.

После обучения нейросети на тренировочных выборках был запущен процесс прогнозирования на тестовых. Пример результата прогноза для акций Сбербанка представлен на рисунке 2.



Рисунок 2 – Прогноз цены акций Сбербанк с 21.11.2018 по 16.05.2019

Далее был проведен бэктестинг прогнозных данных (или в нашем случае имитация торговли по предсказанным сигналам). В качестве первоначального капитала была выбрана сумма 100 тыс. руб. Учтены также комиссии (брокера, биржи и т.д.), равные 0,05% от суммы сделки – это средний показатель по российскому рынку в целом. График изменения результатов имитации торговли акциями Сбербанка можно увидеть на рисунке 3.




Рисунок 3 – Портфолио счета, торгующего акциями Сбербанк с 21.11.2018 по 16.05.2019

Результаты имитации торговли за тот период акциями Tesla, Google и Газпром также демонстрировали положительную динамику с несколько менее впечатляющей прибылью.

В дальнейшем для улучшения качества прогнозирования курсов акций планируется добавить больше входных переменных, а также создать гибридную сверточную и рекуррентную нейросетей.

Библиографический список

1. Хайкин С. Нейронные сети. Полный курс. – М: Вильямс, 2017. – 1104 с.

2. Николенко С. Глубокое обучение. Погружение в мир нейронных сетей / Сергей Николенко, А. Кадурин, Екатерина Архангельская. – Санкт-Петербург: Питер, 2018. – 480 с.

3. Tariq Rashid. Make Your Own Neural Network – CreateSpace Independent Publishing Platform, 2016. – 222 p.

4. Google Colaboratory [Электронный ресурс] // URL: <https://colab.research.google.com> (дата обращения 18.05.2019).

5. Keras [Электронный ресурс] // URL: <https://keras.io/> (дата обращения 18.05.2019).

6. Мальцев В.А. Оптимизаторы нейронных сетей // Научный форум: Инновационная наука: сб. ст. по материалам XXII междунар. науч. практ. конф. – № 4(22). – М., Изд. «МЦНО», 2019. – С. 61 – 65.

УДК 330.45

Моделирование операционно-инновационной программы корпорации

С.И. Межов, И.С. Межов

АлтГУ, г. Барнаул

Актуальность исследования современной промышленной корпорации определяется закрытостью ее экономики, механизмов инвестирования, учета издержек и методов возмещения затрат на инновации. Очевидно, что:

1. Крупные западные корпорации тратят на полный цикл инноваций большие средства из собственных источников.

2. Инновационные затраты в воспроизводственном цикле окупаются за счет прибыли от общих объемов продаж всей продукции компании.

3. При полном инновационном цикле компания получает доход как сумму ренты и среднеотраслевой прибыли.

4. Практическая реализация прогнозного планирования операционно-инновационной программы (ОИП) требует совмещения большого количества финансовых и технологических параметров. Для установленных жизненных циклов каждого изделия ОИП необходимо:

1) определить сроки запуска новых изделий в производство, которые обеспечат экономические показатели эффективности;

2) определить оптимальные объемы и темпы инвестирования инноваций соблюдая равновесие между рентабельностью и ликвидностью. Это можно осуществить в рамках оптимальной ОИП, в которой достигается баланс операционного дохода и отдачи от инвестиций.