

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ СТОИМОСТИ ЦЕННЫХ БУМАГ

APPLICATION OF NEURAL NETWORKS FOR PREDICTING THE VALUE OF SECURITIES

A. Solobuto
V. Pavlov

Summary. This paper explores the application of neural networks as a tool for predicting the value of securities based on historical data. To train the model, data preprocessing is carried out, including the construction of time series, which allows for the identification of hidden dependencies between variables. To improve the model's robustness to outliers and reduce the risk of overfitting, regularization methods such as Dropout and L2 normalization are employed. In addition, appropriate activation functions and a loss function were selected to address the specific task. The study demonstrates the potential of neural network approaches in financial forecasting and highlights the importance of selecting the right architecture and tuning model parameters according to the characteristics of the input data.

Keywords: neural networks, time series, regularization, stocks, indicators.

Солобута Алексей Викторович

аспирант,

Московский финансово-юридический университет

29352138@s.mfua.ru

Павлов Валерий Анатольевич

Кандидат экономических наук, доцент,

Московский финансово-юридический университет

29359332@s.mfua.ru

Аннотация. В данной работе рассматривается применение нейронных сетей в качестве инструмента для прогнозирования стоимости ценных бумаг на основе исторических данных. Для обучения модели проводится предобработка информации о ценных бумагах, включая формирование временных рядов, что позволяет выявлять скрытые зависимости между параметрами. С целью повышения устойчивости модели к выбросам и уменьшения риска переобучения используются методы регуляризации, такие как Dropout и L2-нормализация. Кроме того, для решения поставленной задачи были отобраны подходящие функции активации и функция потерь. Работа демонстрирует потенциал нейросетевых подходов в задачах финансового прогнозирования и подчеркивает важность выбора архитектуры и настроек параметров модели в зависимости от характеристик исходных данных.

Ключевые слова: нейронные сети, временные ряды, регуляризация, ценные бумаги, индикаторы.

Введение

Стремительное улучшение алгоритмов машинного обучения открыло новый этап в развитии экономики и значительно расширило её прикладные возможности в сфере финансов и анализа данных. Одним из ключевых направлений этого развития стало применение методов машинного обучения к анализу фондового рынка. Вследствие этого прогресса, технический анализ, существовавший на протяжении всей истории функционирования финансовых бирж, вышел на принципиально новый уровень. Теперь, благодаря использованию систем поддержки принятия инвестиционных решений и значительным вычислительным мощностям, появилась возможность в реальном времени анализировать огромные объёмы информации и мгновенно принимать решения о совершении сделок на основе выявленных закономерностей и рыночных сигналов [1].

Одним из наиболее перспективных и активно применяемых инструментов машинного обучения в данной области являются нейронные сети. Эти модели особенно ценны своей способностью выявлять сложные, скрытые и нелинейные зависимости в больших массивах данных.

Использование нейронных сетей позволяет более точно прогнозировать поведение финансовых инструментов, определять потенциальные точки входа, также адаптироваться к быстро меняющимся условиям финансовых рынков.

В рамках данной работы будут подробно рассмотрены особенности функционирования нейронных сетей при работе с биржевыми данными, включая вопросы их архитектуры, подготовки входных данных, выбора параметров и методов обучения. Будет проведено построение и обучение модели на основе исторических данных биржевых показателей. Кроме того, особое внимание будет уделено анализу результатов прогнозирования, что позволит объективно оценить эффективность применения нейронных сетей в задачах предсказания рыночной стоимости ценных бумаг. Полученные выводы могут служить основой для дальнейшего исследования в данной области и способствовать развитию более точных и надёжных систем автоматического трейдинга.

Источником данных являются 15-минутные данные по бумагам, входящим в индекс мосбиржи 2014 по 2023 годы.

Анализ актуальных исследований в области

Прогнозирования цены акций с помощью нейросетей рассматривается в нескольких работах. В статье «Нейросетевое прогнозирование на рынке ценных бумаг» авторы детально рассматривают процесс обучения нейронной сети на небольшом временном интервале [2].

Также рассматривается применение нейронных сетей в работе «Использование нейронных сетей для прогнозирования стоимости акций на основе новостных данных» в ней автор рассматривает эффективность применения языковых моделей для прогнозирования курса акций [3].

В качестве альтернативного решения задачи прогнозирования, в данной работе предлагается работать с историческими данными по ценным бумагам, как с временным рядом, используя все основные биржевые индикаторы для прогноза.

Предобработка данных

Для обучения нейросети необходимо провести преобразование данных во временной ряд, для этого необходимо провести расчёт всех индикаторов за каждый участок временного интервала. Так, например, для данных за 15 минут необходимо посчитать значения для каждой из предыдущих минут — данный подход позволяет увеличить количество входов нейронной сети, что даёт возможность находить зависимости между большим количеством параметров, чем в других методах машинного обучения [4].

Преимущества и недостатки нейронных сетей

Нейросети могут иметь самую разную архитектуру, в зависимости от задачи, что создает ряд весомых преимуществ, но и накладывает ряд ограничений. К преимуществам следует отнести:

- 1) Возможность дообучать модель на новых данных, используя уже существующую — это позволяет экономить время в задачах, где постоянно приходится иметь дело с новыми данными.
- 2) Возможность находить нелинейные зависимости между данными
- 3) Параллельная обработка данных

К недостаткам же следует отнести:

- 1) Невозможность интерпретировать
- 2) Требования к большим вычислительным мощностям — данная задача за адекватное количество времени решается только на GPU
- 3) Для обучения необходимо большое количество данных, иначе существует высокий риск недообучения.

Исходя из перечисленного, можно сказать, что для задачи прогнозирования курса ценных бумаг, применение нейронных сетей является эффективным, так как для работы с биржевыми данными необходимо постоянно обновлять модель, а большая часть биржевых параметров нелинейно связана с ценой.

Выбор функции активации

Для решения задачи регрессии используются несколько основных функций активации: Linear, ReLU, Leaky ReLU и Swish.

Функция активации Linear подходит, если между входными переменными имеется линейная зависимость [4], что не подходит в рамках данной задачи, так как большая часть параметров связаны между собой нелинейно.

Для данной задачи базовая реализация ReLU также не является целесообразной, т.к. она обнуляет отрицательные значения [5], что не позволяет заходить в короткие позиции.

Из оставшихся функций активации выбор остановился на Leaky ReLU, поскольку функция активации swish подходит для нейросетей с числом скрытых слоев больше 40 [6], что делает её более подходящей для работы с изображениями, чем с табличными данными.

Выбор функции потерь

Из двух основных функций потерь MAE и MSE выбор был сделан в пользу MAE, так как среди данных по ценным бумагам присутствует огромное количество выбросов, что может привести к переобучению при использовании MSE [7].

Описание архитектуры

Количество слоев нейронной сети равно 9, количество нейронов на входном слое равно 256, каждый слой в 2 раза меньше предыдущего, в качестве функции активации на каждом слое используется Leaky ReLU [8], также после каждого слоя применяются методы регуляризации batch normalization [9] и dropout [10].

Leaky ReLU возвращает само значение при положительном входном значении, а при отрицательных значениях возвращает линейную функцию от входа, умноженную на небольшой коэффициент, называемый отрицательным уклоном (leak). Таким образом, у нейрона всегда есть возможность вносить вклад в выходную функцию, даже если входные данные отрицательны. Что позволяет избежать переобучения, связанного с использованием индикаторов, принимающих отрицательные значения.

Способ регуляризации Batch Normalization решает сразу несколько задач: борется со взрывом градиента, улучшает сходимость обучения, уменьшает зависимость от гиперпараметров и влияние инициализации весов. Все эти проблемы являются критичными для данной модели, т.к. используется большое количество входных сигналов нейронной сети и какая-то комбинация может просто минимизировать эффект всех остальных нейронов. Также в качестве регуляризации применяется dropout, чтобы минимизировать влияние конкретных нейронов, ускорить обучение и минимизировать шанс переобучения.

В качестве функции потерь была выбрана MAE, так как стояла необходимость минимизировать влияние выбросов [11], которых в исторических данных по фондовым рынкам значительная часть.

Также был использован метод адаптивной оценки моментов Adaptive Moment Estimation, Adam. Данный метод сходится к локальному минимуму быстрее большинства базовых алгоритмов оптимизации [12], что важно при работе с большим количеством признаков.

Обучение нейронной сети

Данная нейронная сеть обучается в 500 итераций. В одной итерации происходит обнуление градиентов

в оптимизаторе, прямое распространение, подсчёт значения функции потерь, вычисление градиента для функции потерь, изменение весов с помощью оптимизатора, вычисление метрики качества.

Также в процессе обучения все данные делятся на наборы по 128 объектов, чтобы оптимизировать затраты по оперативной памяти.

На каждом этапе происходит накопление градиентов следующим образом: старые градиенты весов и сдвигов нейронной сети после обратного распространения ошибки суммируются с новыми.

После обучения модели проведена проверка на тестовых данных, где MAPE = 0.024.

Заключение

Рассмотренная архитектура нейронной сети показала результат MAPE = 0.024, что говорит о возможности её использовать в реальных моделях принятия решений. В дальнейшем можно расширять подобный подход, меняя архитектуру сети, подбирая регуляризацию к конкретным нейронам и отбирая индикаторы для модели, что позволит ещё сильнее снизить погрешность модели.

ЛИТЕРАТУРА

1. Ernie Chan Algorithmic Trading. Winning Strategies and Their Rationale. — 1-е изд. — San Francisco: Wiley, 2017. — 225 с.
2. Лобачёва Е.Н., Кузнецова Т.И., Кульчицкий С.Е. Нейросетевое прогнозирование на рынке ценных бумаг // Гуманитарный вестник МГТУ им. Н.Э. Баумана. — 2020. — №5. — С. 153–161.
3. Использование нейронных сетей для прогнозирования стоимости акций на основе новостных данных // Сайт экономического факультета МГУ URL: <https://www.econ.msu.ru/sys/raw.php?o=97187&p=attachment> (дата обращения: 15.07.2025).
4. Vinod Nair, Geoffrey E. Hinton Rectified Linear Units Improve Restricted Boltzmann Machines // 27th International Conference on International Conference on Machine Learning. — Toronto: Omnipress, 2010. — С. 807–814.
5. Michael S. Gashler, Stephen C. Ashmore Training Deep Fourier Neural Networks to Fit Time-Series Data // International Conference on Intelligent Computing. — Cham: Springer, 2010. — С. 48–55.
6. Bing Xu, Naiyan Wang, Tianqi Chen, Mu Li. Empirical Evaluation of Rectified Activations in Convolutional Network // Computer Vision and Pattern Recognition. — 2015. — №32. — С. 28–33.
7. Павлов В.А., Солобута А.В. Предобработка данных в задаче прогнозирования динамики ценных бумаг // Современные и информационные технологии в социальной сфере. — Чебоксары: Волжский филиал МАДИ, 2024. — С. 42–45.
8. A Continuum among Logarithmic, Linear, and Exponential Functions, and Its Potential to Improve Generalization in Neural Networks // scitepress URL: <https://www.scitepress.org/papers/2015/56358/56358.pdf> (дата обращения: 15.07.2025).
9. Batch Normalization in Deep Networks // LearnOpenCV URL: <https://learnopencv.com/batch-normalization-in-deep-networks/> (дата обращения: 15.07.2025).
10. Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov Dropout: A Simple Way to Prevent Neural Networks from Overfitting // Journal of Machine Learning Research. — 2014. — №15. — С. 1930–1960.
11. Klebanov L., Rachev S.T., Fabozzi F. Robust and Non-Robust Models in Statistics. — 1-е изд. — New York: Nova Scientific Publishers, 2009. — 225 с.
12. Why Momentum Really Works // Distill URL: <https://distill.pub/2017/momentum/> (дата обращения: 15.07.2025).

© Солобута Алексей Викторович (29352138@s.mfua.ru); Павлов Валерий Анатольевич (29359332@s.mfua.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»