

*Амирасланов Эльмар Гейдар Оглы*¹,
аспирант;
*Сараджишвили Сергей Эрикович*²,
доцент, канд. техн. наук, доцент

ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ С ЦЕЛЬЮ ПРОГНОЗИРОВАНИЯ ИЗМЕНЕНИЯ ЦЕН АКЦИЙ

^{1,2} Россия, Санкт-Петербург,
Санкт-Петербургский политехнический университет Петра Великого,
¹ elmar0131@gmail.com, ² ssaradg@yandex.ru

Аннотация. В данной работе рассматривается вопрос актуальности использования методов глубокого обучения с целью прогнозирования цен акций, сравнение существующих алгоритмов, предложен метод использования долговременной краткосрочной памяти (LSTM), отличный от существующих.

Ключевые слова: прогнозирование цен акций, методы глубокого обучения, LSTM, обработка данных.

*Elmar G. Amiraslanov*¹,
Postgraduate Student;
*Sergei E. Saradgishvili*²,
Associate Professor, Candidate of Technical Sciences

USING MACHINE LEARNING METHODS TO PREDICT STOCK PRICE CHANGES

^{1,2} Peter the Great St.Petersburg Polytechnic University, St. Petersburg, Russia,
¹ elmar0131@gmail.com, ² ssaradg@yandex.ru

Abstract. This paper examines the relevance of using deep learning methods to predict stock prices, compares existing algorithms, and proposes a method for using long-term short-term memory (LSTM) that differs from existing ones.

Keywords: stock price predicting, deep learning methods, LSTM, data processing.

Введение

Волатильность фондового рынка делает его сферой, в которой необходимо использовать качественный анализ с использованием старых данных. Существующие алгоритмы в прогнозировании, в большинстве своем, используют информацию с ежедневным колебанием цен на рынке в виде паттернов. Одним из ключевых инструментов, который определяет краткосрочные паттерны, являются методы глубокого обучения. Их

использование приводит к точечному обнаружению различных экономических и новостных факторов для выстраивания долгосрочных зависимостей. В последние годы развитие нейронных сетей напрямую коррелирует с точностью прогнозирования фондового рынка.

Важно понимать, что на цену акций влияет множество различных неконтролируемых факторов, таких как профиль компании, новостной фон, социальная позиция и т. д. В таких случаях приходится изучать и обрабатывать большой поток данных для повышения качества прогнозирования. Аналитики и трейдеры в основе предсказания движения цен акций используют рекуррентный метод глубокого обучения, так называемую долговременную краткосрочную память. В качестве данных для обучения такой модели использую следующие характеристики акций: цена открытия, максимум от дневного движения цены, дневной минимум, цена закрытия предыдущего торгового дня. Методы глубокого обучения являются основополагающими элементами прогнозирования будущих движений. С помощью них модели обучаются на сложных данных, которые они получают, чтобы улучшить алгоритмы, в соответствии с которыми они работают.

Нейронные сети позволяют в дальнейшем принимать решения о том, как действовать, без необходимости получения конкретных инструкций для каждой потенциальной ситуации. Чтобы сделать работу систем автономными, создаются искусственные симуляции для проверки их возможностей. Для создания таких симуляций используется тестирование «черного ящика» и «белого ящика». Тестирование белого ящика, при котором внутренняя структура тестируемой системы известна тестировщику, может доказать отсутствие сбоев. Методы «черного ящика» гораздо сложнее и предполагают использование более состязательного подхода. Эти методы пытаются найти слабые места в системе, чтобы гарантировать ее соответствие высоким стандартам анализа данных.

Как правило анализ фондовых рынков, с давних времен, основан на двух стратегиях: фундаментальный и технический анализ. В основе технического анализа лежит оценка акционерами фондового рынка с помощью различных индикаторов, таких как индекс относительной силы (RSI), скользящие средние и осциллирующий индикатор (MACD). При обучении моделей машинного обучения так же можно внедрить использование этих индикаторов, что приведет к нахождению логических взаимосвязей между дневной ценой закрытия торгов и финансовыми показателями компании. С другой стороны, акционеры тщательно изучают финансовые отчеты компании, дивидендную политику, используют инсайдерскую информацию. Очевидно, что любые изменения в отчетах компании приводят к немедленному реагированию со стороны держателей акций в пользу покупки/продажи. Далее рассмотрим детальнее используемые модели для прогнозирования движения цен акций.

1. Существующие решения и индикаторы

Первым делом для построения моделей глубокого обучения необходимо получить доступ к набору данных. Этот набор должен включать в себя некоторые функции, которые обучают модель. Обучение может проходить как с набором помеченных данных, их так же называют целевыми значениями, так и без них. Если при обучении используются только целевые значения, то процедура обучения является контролируемой. В обратном случае, где целевые значения не участвуют в обучении, модель пробует находить скрытые закономерности в имеющихся данных.

Чаще всего модели глубокого обучения используют данные с целевыми значениями. В такой набор данных включены финансовые показатели, такие как RSI, MACD, цена открытия и закрытия торгового дня. При техническом анализе данные представляют собой непрерывный набор чисел, которые используются в формате временных рядов. И технический и фундаментальный анализ на этапе обучения модели используют следующие показатели: SMA, EMA, RSI, MACD. Ниже рассмотрим подробнее эти показатели.

SMA. Показатель использует среднее значение последних цен закрытия торгового дня за определенный период. Сам расчет SMA использует расчет, указанный ниже:

$$SMA(t,N) = \sum_{k=1}^N \frac{CP(t-k)}{N},$$

где CP – цена закрытия торгового дня, N – количество дней, в котором учитываем цену закрытия, k – дни, связанные с конкретными CP.

EMA. Данный индикатор схож по принципу с SMA, но в нём большее значение имеют последние цены закрытия торгов, тем самым их коэффициент больше. Расчет индикатора показан ниже:

$$EMA(t,N) = (CP(t) - EMA(t-1)) * \Gamma + EMA(t-1),$$
$$\Gamma = \frac{2}{N+1},$$

где t – текущий день, N – количество дней, а Γ – сглаживающий коэффициент.

MACD. Индикатор предназначен для сравнения долгосрочной и краткосрочной тенденции изменения цены акций. Уравнение для расчета индикатора указано ниже:

$$MACD = EMA(t,K) - EMA(t,d),$$

где показатели k и d – период для расчета краткосрочных и долгосрочных трендов. Принято использовать следующие значения $d = 16$ и $k = 12$.

RSI. Данный индикатор является одним из важнейших при изучении движения цены акции. Он выявляет перепроданность или же перекупленность ценной бумаги. Индикатор является своего рода показателем

будущего тренда движения и настроения держателей акций. Индекс RSI рассчитывается по следующей формуле:

$$RSA = \frac{100}{1+RS(t)}, \quad RS(t) = \frac{AvgGain(t)}{AvgLoss(t)},$$

где $RS(t)$ – это уровень доходности акции, $AvgGain(t)$ – средняя полученная прибыль акции в момент времени, $AvgLoss(t)$ – средний полученный убыток в момент времени.

2. Модели машинного обучения

Модели машинного обучения использовались в научных исследованиях для прогнозирования фондовых рынков. Категории моделей делятся на два вида: классификационные модели и регрессионные модели. В качестве помощи инвесторам в процессе принятия решений о покупке или продаже акций участвуют классификационные модели. В свою очередь, регрессионные модели используют скрытые взаимосвязи при обработке данных для предсказания будущего движения цены акций.

Среди алгоритмов машинного обучения для прогнозирования фондовых рынков больше популярностью пользуются следующие: Метод опорных векторов (SVM), искусственные нейронные сети (ANN), дерево решений (DT) и также модель долговременной краткосрочной памяти (LSTM). Рассмотрим их детальнее ниже.

ANN. Искусственные нейронные сети изначально были основаны на биологических концепциях, которые обрабатывали нейроны. Основной целью взаимосвязанных нейронов было суммирование входных параметров, в соответствии с их заданными коэффициентами, а затем их смещение. При этом количество нейронов на входе должно равняться количеству выходных параметров. При прогнозировании движения цен акций используют передаточные функции для анализа динамического изменения рынка.

DT. Каждая ветвь дерева решений представляет результат тестирования, а лист дерева указывает на элемент класса. Внутренние узлы дерева отвечают за разветвление по определенному атрибуту. Выходным результатом при обучении данной модели является атрибут, соответствующий наилучшему классу.

SVM. Модель опорных векторов использует контролируемый метод обучения, который необходим для классификации, регрессии и выявления расхождений. Опорными векторами в данном случае являются точки на графике. Затем алгоритм вычисляет расстояние между ними, находит наибольший зазор и строит линию или гиперплоскость, которая разделяет данные на классы.

LSTM. Долговременная краткосрочная память является типом рекуррентной нейронной сети (RNN), которая разработана для решения задач предсказания последовательностей. В отличие от традиционных RNN,

LSTM могут находить и фиксировать долгосрочные зависимости для дальнейшего моделирования последовательности с учетом временных периодов. Все это благодаря использованию сложной архитектуры модели, которая использует ячейки памяти, входные и выходные параметры, и элементы забывания. Ячейки памяти позволяют LSTM запоминать информацию длительный период времени, и при этом элементы управления регулируют поток входной информации. Для полного понимания LSTMS необходимо: разбираться в смежных концепциях, таких как двунаправленное моделирование и архитектуры «последовательность за последовательностью». Двунаправленные LSTM используют информацию как из прошлых, так и из будущих входных данных, улучшая понимание модели текущего контекста. Этот двунаправленный подход полезен в таких задачах, как анализ больших входных данных, где движение графика прогнозирования зависит от предыдущих данных.

В архитектурах Sequence-to-sequence используются LSTM для сопоставления входных последовательностей с выходными. Это особенно полезно в таких задачах, как машинный перевод, когда входная последовательность (исходный язык) должна быть переведена в выходную последовательность (целевой язык). LSTM позволяют модели кодировать входную последовательность в виде представления фиксированного размера, а затем декодировать ее в желаемую выходную последовательность.

3. Реализованный алгоритм LSTM для прогнозирования

В качестве данных я использовал финансовый инструмент Yahoo Finance. В нем реализован доступ к данным о фондовом рынке благодаря собственной библиотеке `yahoolib`. Данные о фондовом рынке доступны с 1970 года, что позволяет получить исчерпывающую детальную информацию о движении цены акций для нашего анализа.

В основе анализа и обучения модели была использования компания Apple, которая является самой большой компанией по капитализации, и довольно небольшая дневная волатильность внутри торгового дня. Для качественного обучения модели были использованы следующие параметры входных данных торгового дня: цена открытия, самая высокая цена, самая низкая цена, цена закрытия, скорректированная цена закрытия, сумма всех проведенных сделок. Входные данные были взяты за период с 07.04.2022 по 20.11.2023. Полученные данные указаны на рис. 1.

Для повышения эффективности анализа входных данных был использован индикатор RSI, который позволяет увидеть перепроданность или же перекупленность в определенный период времени. Это позволяет модели учитывать настроение рынка и движение по бычьему/медвежьему тренду. Индикатор показан в виде линии под графиком цены акции, где значения выше 70 указывают на состояние перекупленности, а значение ниже 30 указывает на значение перепроданности. Пересечение RSI с этими

пороговыми значениями трейдеры чаще всего используют как потенциальный сигнал для покупки или продажи. Индикатор RSI компании Apple в период с 07.04.2022 по 20.11.2023 указан ниже на рис. 2.

	Open	High	Low	Close	Adj Close	Volume	company_name
Date							
2022-04-07	171.160004	173.360001	169.850006	172.139999	170.195068	77594700	APPLE
2022-04-08	171.779999	171.779999	169.199997	170.089996	168.168213	76575500	APPLE
2022-04-11	168.710007	169.029999	165.500000	165.750000	163.877243	72246700	APPLE
2022-04-12	168.020004	169.869995	166.639999	167.660004	165.765671	79265200	APPLE
2022-04-13	167.389999	171.039993	166.770004	170.399994	168.474716	70618900	APPLE

Рис. 1. Входные данные для обучения модели



Рис. 2. Индикатор RSI компании Apple

Далее в качестве еще одного параметра для обучения был использован показатель волатильности акции. Этот показатель указывает на рискованные точки покупки акции, так как график цены может сильно колебаться в короткий период времени. Высокая волатильность может служить очевидным знаком для долгосрочных инвесторов как сигнал к продаже – это напрямую влияет на настроение рынка, что тоже необходимо учитывать при прогнозировании.

После запуска обучения LSTM модели получаем выходные данные в формате: дата, цена закрытия, спрогнозированная цена закрытия. На основе этих данных смоделируем график, где наглядно будет видно, как результаты движения цены мы получили. Результат прогнозирования движения цены акции компании Apple после обучения LSTM модели указан ниже на рис. 3.



Рис. 3. Результат прогнозирования цены акции LSTM Модели

Заключение

В рамках данной работы был рассмотрен проект обучения LSTM модели на 1,5 годовых данных для дальнейшего предсказания движения цены акции компании Apple. В ходе работы были изучены и проанализированы модели машинного обучения, была подробно рассмотрена существующие индикаторы для анализа фондового рынка, наполнение и способы применения, понятие нестабильной передачи данных.

Список литературы

1. История беспилотных автомобилей [Электронный ресурс]. – URL: <https://be-pilot.com/info/istoriya> (дата обращения: 10.02.2024).
2. Muhammad F., Kamran A. Financial prices prediction of stock market using supervised machine learning models // VFAST Transactions on Software Engineering. – 2023. – Vol. 11. – No. 2 (April–June 2023). – Pp. 1–10.
3. Zhneg A., Jin J. Using AI to make predictions on stock market [Electronic resource]. – 2023. – URL: <https://cs229.stanford.edu/proj2017/final-reports/5212256.pdf> (access date: 22.05.2024).
4. An open source machine learning framework for everyone [Electronic resource] // TensorFlow. – URL: <https://www.tensorflow.org> (access date: 22.05.2024).
5. Hopsfs: Scaling hierarchical file system metadata using newsq databases / S. Niazi [et al.]. – 2017. – Pp. 107–123.
6. Обработка и классификация речевых сигналов в системах распознавания речи / А. К. Алимуратов [и др.] // Измерение. Мониторинг. Управление. Контроль. – 2015. – № 2. – С. 27–35.
7. Ermakov N. V., Molodyakov S. A. A caching model for a quick file access system // Journal of Physics: Conference Series. – IOP Publishing, 2021. – Vol. 1864. – No. 1. – DOI:10.1088/1742-6596/1864/1/012095.