

ДЕТЕКТИРОВАНИЕ УРОВНЕЙ ПОДДЕРЖКИ И СОПРОТИВЛЕНИЯ С ИСПОЛЬЗОВАНИЕМ БЛОКА АВТОМАТИЧЕСКОЙ ГЕНЕРАЦИИ ПРИЗНАКОВ

Хайров М.А.¹, Спицын В.Г.²

1 НИ ТПУ, ИШИТР, А2-39, e-mail: mah9@tpu.ru

2 НИ ТПУ, ИШИТР, ОИТ, профессор, e-mail: spvg@tpu.ru

Аннотация

В работе исследуется прогнозирование динамики цен фондового рынка на основе уровней поддержки и сопротивления с использованием глубокого обучения. В результате работы удалось создать классификатор с высокой точностью благодаря применению блока автоматической генерации признаков на основе каузальных свёрток. В работе показано, что значимые признаки для прогнозирования уровней поддержки и сопротивления могут быть получены при помощи линейных преобразований данных по ценам и объёмам.

Ключевые слова: market quote data, deep learning, causal convolution, уровни поддержки, уровни сопротивления.

Введение

В академической литературе представлены сведения об эффективности моделирования динамики цен фондовых рынков при помощи моделей глубокого обучения [1, 2]. В качестве показателя динамики цен во многих работах используется направление движения средней цены. Такой показатель прост в имплементации и понятен для восприятия, но это не единственный способ описания динамики цен на рынке. На практике на протяжении нескольких десятилетий [3] применяется такие индикаторы как уровни поддержки и сопротивления (также локальные уровни цен), которые известны своей способностью влиять на направление движения трендов цен [3]. Однако, несмотря на их практическую значимость, механизмы формирования этих уровней до сих пор недостаточно изучены [4].

В данной работе исследуется использование уровней поддержки и сопротивления (локальных уровней цены) в качестве показателя динамики цен. Предсказание уровней поддержки и сопротивления может быть полезно инвесторам или финансистам для оценки инвестиционной привлекательности актива и финансовым инженерам или трейдерам для использования торговых стратегий.

В работе показано, что значимыми признаком для прогнозирования уровней поддержки и сопротивления могут быть получены при помощи линейных преобразований данных по лучшим ценам на покупку и продажу и их объёмам.

Целью работы являлась разработка алгоритма для предсказания уровней поддержки и сопротивления, способного генерировать релевантные признаки на основе данных лучших цен на покупку и продажу активов и их объёмов.

Данные и их подготовка

Для моделирования экспериментов были отобраны данные NBBO по четырём активам AAPL, MSFT, GE и AMZN за период с 26.01.2023 по 17.02.2023 (18 дней). Такие данные содержат лучшие цены на покупку $a(t)$ и продажу $b(t)$ активов, а также их объёмы - $v_a(t)$ и $v_b(t)$.

В обучающую выборку вошли первые 12 дней (с 26.01.2023 по 09.02.2023), для валидационной и тестовой выборок было выделено по 3 (10.02.2023-14.02.2023 и 15.02.2023-17.02.2023 соответственно).

Для обучения тестов и валидации были отобраны исторические данные только в пределах часов осуществления торговли (с 9:30 до 16:00 GMT-5).

К признакам к каждому из дней по-отдельности была применена процедура стандартизации при помощи z-score (1), статистики для стандартизации (средние значения μ и стандартные отклонения σ) каждого признака в рамках одного дня рассчитывались по 5 предшествующим дням [2, 5]

$$z = \frac{x - \mu}{\sigma}, \quad (1)$$

Разметка данных

Задача предсказания уровней поддержки и сопротивления была сведена к классификации. В датасет попали следующие классы:

1. уровень поддержки;
2. уровень сопротивления;
3. нейтральное наблюдение (класс).

Определения уровней поддержки и сопротивления использовались аналогичные тем, что использовались в [6]:

$$R = \max(m(t-T), m(t-T+1), \dots, m(t+T)) \pm \pi, \quad (2)$$

$$S = \min(m(t-T), m(t-T+1), \dots, m(t+T)) \pm \pi, \quad (3)$$

$$m(t) = \frac{a(t) + b(t)}{2}, \quad (4)$$

где T – размер окна поиска; π – наименьшее возможное приращение цены; $m(t)$ – средняя цена.

В качестве примеров для обучения моделей использовались только наблюдения, которые соответствовали образованию новых уровней поддержки и сопротивления. Такие уровни поддержки/сопротивления соответствуют двум случаям: (i) – началу времени торговли, когда наблюдаемый уровень поддержки/сопротивления является первым зарегистрированным с момента начала торговых часов; (ii) – появлению более актуального уровня поддержки/сопротивления (актуальность обусловлена интервалом $[t-T; t+T]$, который задаёт скользящее окно). Параметр T имел фиксированное значение, равное 100 наблюдениям.

В примеры нейтрального класса вошли случайные наблюдения, которые не являлись ни уровнями поддержки, ни сопротивлением.

Разработка классификаторов

Входной тензор имеет вид $\mathbf{X} = [x_1, x_2, \dots, x_i, \dots, x_{100}]^T \in \mathbb{R}^{100 \times 4}$, где $x_i = [a_i, v_{a,i}, b_i, v_{b,i}]$. Значение 100 соответствует количеству наблюдений, используемых для осуществления предсказаний, а 4 – количеству признаков.

Для осуществления автоматической генерации признаков используется каскад одномерных каузальных свёрток (от англ. *causal convolutions*) [7] наподобии того, что было использовано в работе Тсантекидеса и др. [8]. Особенность каузальной свёртки заключается в том, что каждый i -ый элемент выходной последовательности зависит только от предшествующих j -ых элементов входа ($j \leq i$). Каузальность свёрток обеспечивается за счёт каузального паддинга.

Блок генерации был совмещён в отдельном порядке с такими базовыми архитектурами как *Long short-term memory (LSTM)*, многослойный перцептрон (*MLP, Multilayer Perceptron*) и логистическая регрессия. Также для контрастного анализа были обучены модели без использования свёрточных блоков по генерации признаков.

На рис. 1 представлены архитектуры моделей *CNN-LSTM*, *CNN-MLP* и *CNN-LM*. Модели без использования блока автоматической генерации признаков имели схожую архитектуру. Единственное отличие состояло в том, что для *CNN-LSTM*, *CNN-MLP*, *CNN-LM* и *LSTM* ввод имел размерность/формат (100, 4), для моделей *MLP* и *LM* использовался формат ввода (100×4).

В качестве функции активации в многослойном перцептроне применялась функция ReLU. В финальной версии блоков генерации признаков на выходе слоёв каузальных свёрток не были задействованы функции активации, т.к. в результате экспериментов с различными функциями активации лучший результат был достигнут на блоках свёртки без функций активации.




Рис. 1. Архитектуры моделей:
слева – CNN-LSTM; по середине – CNN-MLP; справа - CNN-LM

Результаты

В таблице ниже представлены метрики качества, которые были получены на тестовой выборке. Отсюда видно, что блок генерации позволил значительно улучшить качество предсказаний для LSTM и многослойного персептрона.

Таблица 1

Результаты тестов

Модель	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>LM</i>	56.65	55.67	56.65	55.86
<i>MLP</i>	58.91	57.57	58.10	57.77
<i>LSTM</i>	59.94	60.71	59.94	59.96
<i>CNN-LM</i>	54.20	53.69	54.20	53.86
<i>CNN-MLP</i>	65.10	63.57	63.45	63.50
<i>CNN-LSTM</i>	71.00	71.46	71.00	71.18

На рис. 2 представлены матрицы ошибок для моделей *CNN-LSTM*, *CNN-MLP* и *CNN-LM*. Здесь видно, что наиболее проблемным классом является нейтральный класс. Отсюда можно предположить, что определение нейтрального класса включает в себя наблюдения с самой различной динамикой предшествующих и последующих наблюдений. Вероятно, включение дополнительных условий для вхождения наблюдения в нейтральный класс позволит улучшить результаты предсказаний.

Тот факт, что между слоями свёртки не было использовано никаких функций активации, может означать, что для предсказания уровней поддержки и сопротивления существуют некоторые значимые признаки, которые могут быть получены при помощи линейных преобразований (например, такие как скользящие средние).




Рис. 2. Матрицы ошибок:
 а – CNN-LSTM; б – CNN-MLP; в – LSTM

Заключение

В результате работы удалось получить модели с высокой предсказательной способностью для финансовых данных. Достичь этих результатов позволил блок по автоматической генерации признаков на основе каузальных свёрток. Возможно, уточнение определения нейтрального класса позволит улучшить качество предсказаний.

Было показано, что для прогнозирования уровней сопротивления и поддержки могут быть использованы некоторые признаки, полученные при помощи линейных преобразований из данных по лучшим ценам на покупку и продажу и их объёмов.

В следующих работах планируется доработать определения нейтрального класса и проверить практическую значимость используемых методов при помощи симуляции биржевой торговли.

Список использованных источников

1. Justin Sirignano and Rama Cont. Universal features of price formation in financial markets: Perspectives from deep learning. SSRN Electronic Journal. – 2018.
2. Zhang Z., Zohren S. and Roberts S. DeepLOB: Deep Convolutional Neural Networks for Limit Order Books // IEEE Transactions on Signal Processing. – 2019. – Vol. 67, No. 11. – P. 3001-3012. Doi: 10.1109/TSP.2019.2907260
3. Osler C. L. Support for resistance: technical analysis and intraday exchange rates // Economic Policy Review. – 2000. – Т. 6. – №. 2.
4. Chung K., Bellotti A. Evidence and Behaviour of Support and Resistance Levels in Financial Time Series // arXiv preprint –arXiv:2101.07410. – 2021.
5. Ntakaris A., Magris M., Kannianen J., Gabbouj M., Iosifidis A. Benchmark dataset for mid-price forecasting of limit order book data with machine learning methods // Journal of Forecasting. – 2018. – Vol. 37, No. 8, – P. 852-866.
6. Хайров М.А. Предсказание уровней поддержки и сопротивления цен на фондовом рынке при помощи LSTM // Перспективы развития фундаментальных наук: сборник трудов XX Международной конференции студентов, аспирантов и молодых ученых: в 7 т., Томск, 25–28 апреля 2023 - Томск: ТПУ, 2023 – Т. 7. – С. 148-150
7. Oord A. et al. Wavenet: A generative model for raw audio //arXiv preprint arXiv:1609.03499. – 2016.
8. Tsantekidis A. et al. Using deep learning for price prediction by exploiting stationary limit order book features //Applied Soft Computing. – 2020. – Т. 93. – С. 106401.