

УДК 004.85

ПРЕДСКАЗАНИЕ УРОВНЕЙ ПОДДЕРЖКИ И СОПРОТИВЛЕНИЯ ЦЕН НА ФОНДОВОМ РЫНКЕ ПРИ ПОМОЩИ LSTM

М.А. Хайров

Научный руководитель: профессор, д.т.н. В.Г. Спицын
 Национальный исследовательский Томский политехнический университет,
 Россия, г. Томск, пр. Ленина, 30, 634050
 E-mail: mah9@tpu.ru

SUPPORT AND RESISTANCE LEVELS PREDICTIONS FOR STOCK MARKET WITH LSTM

M.A. Khairov

Scientific Supervisor: Prof., Dr. V.G. Spitsyn
 Tomsk Polytechnic University, Russia, Tomsk, Lenin str., 30, 634050
 E-mail: mah9@tpu.ru

Abstract. *In this study, an LSTM-classifier for stock market support and resistance levels predictions is trained on high-frequency best bid and ask price data.*

Введение. В академической литературе имеются сведения о том, что поведение фондового рынка подчиняется некоторой нелинейной независимой от времени функции [1], в частности было показано, что искусственные нейронные сети могут понимать и предсказывать динамику цен. Таким образом исследования в этой области позволяют приблизиться к пониманию фундаментальных законов рынка.

Целью данного исследования является получение модели глубокого обучения для выявления уровней поддержки и сопротивления цен активов на фондовом рынке.

Экспериментальная часть. Для экспериментов были собраны исторические, содержащие лучшие цены покупки и продажи активов AAPL, MSFT, GE и NVDA за период с 2023.01.19 по 2023.02.21 числа в часы осуществления торгов. Всего в исходных данных содержалось около 83 млн. наблюдений.

Уровни сопротивления и поддержки в работе представлены, как локальные максимумы (1) и минимумы (2) соответственно по средней цене между ценой покупки и продажи (3) [2].

Использовались следующие определения уровней поддержки и сопротивления

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

$$S = \min(m(t-n), m(t-n+1), \dots, m(t+n)) \pm \pi, \quad (2)$$

$$m(t) = \frac{a(t) - b(t)}{2}, \quad (3)$$

где $a(t)$ – наиболее низкая цена продажи; $b(t)$ – наиболее высокая цена покупки; n – размер окна поиска; π – наименьшее возможное приращение цены.

К данным также была применена процедура стандартизации (4), средние значения μ и стандартные отклонения σ рассчитывались по предыдущим 5 дням [3, 4]

$$z = \frac{x - \mu}{\sigma}. \quad (4)$$

В качестве входных признаков использовались значения цен купли и продажи, их объёмы, скользящие средние и стандартные отклонения.

Примеры для обучения модели, её валидации и теста были выбраны из 17. Для обучения модели использовались первые 11 дней, следующие 3 дня из выборки были выделены на валидацию и остальные 3 дня – на тест.

Задача предсказания уровней поддержки и сопротивления была сведена к классификации текущего наблюдения на предмет принадлежности к одному из классов:

- 1) уровень поддержки;
- 2) уровень сопротивления;
- 3) нейтральный класс - наблюдения, не являющиеся ни уровнем поддержки, ни уровнем сопротивления.

В качестве классификатора использовалась искусственная нейронная сеть на основе LSTM-блока с одним полносвязным слоем.

Обучение производилось при помощи стохастического градиентного спуска с использованием техники дропаут (англ. *dropout*) [5].

Результаты. На рис. 1 показано, как изменялась точность в процессе обучения модели.

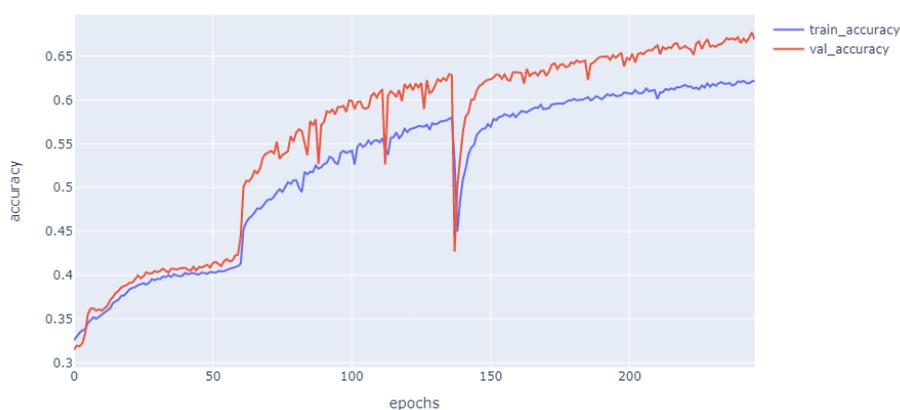


Рис. 1. График обучения ИНС. Изменение точности

Удалось достичь точности классификации на валидационной выборке равной 67 % и 63 % на тестовой из расчёта общей точности по всем классам. В таблице 1 также представлена оценка качества классификации по отдельным классам.

Таблица 1

Результаты, полученные на тестовой выборке (*support* – уровень поддержки, *resistance* – уровень сопротивления, *nothing* – нейтральный класс)

	Precision, %	Recall, %	F1, %	Accuracy, %
Neutral	37,59	46,39	41,53	-
Resistance	76,32	68,72	72,32	-
Support	75,54	70,00	72,66	-
По всем классам	-	-	62,17	63,15

На рис. 2 представлена матрица ошибок, полученная на тестовой выборке. Здесь можно наблюдать, что при определении уровней поддержки и сопротивления модель склонна в большинстве

случаев правильно классифицировать наблюдения, но в случае нейтрального класса большинство предсказаний ошибочны.

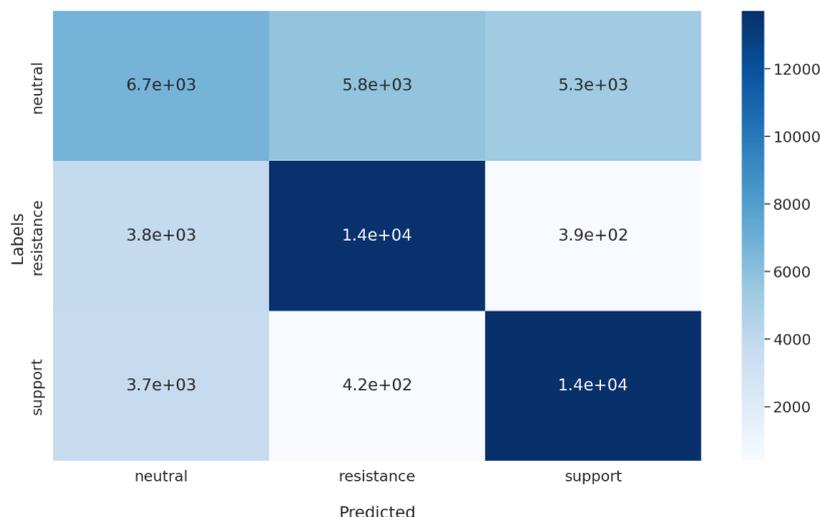


Рис. 2. Матрица ошибок, полученная на тестовой выборке (*support* – уровень поддержки, *resistance* – уровень сопротивления, *nothing* – нейтральный класс)

Заключение. В результате проведенного эксперимента удалось получить классификатор с точностью 63% на тестовой выборке. Обученная модель лучше всего справлялась с классификацией уровней поддержки и сопротивления нежели нейтрального класса, что может указывать на необходимость в использовании определения классов. В дальнейшем планируется: расширить выборки для обучения, валидации и теста; осуществить подбор информативных признаков и произвести симуляцию торговли с применением разработанной модели.

СПИСОК ЛИТЕРАТУРЫ

1. Justin Sirignano and Rama Cont. (2018) Universal features of price formation in financial markets: Perspectives from deep learning. SSRN Electronic Journal, pp. 1-20.
2. Gould, M.D., Porter, M.A., Williams, S., McDonald, M., Fenn, D.J., & Howison, S.D. (2013). Limit order books. Quantitative Finance, no. 13(11), pp. 1709-1742.
3. Zhang Z., Zohren S. and Roberts S., (2019) DeepLOB: Deep Convolutional Neural Networks for Limit Order Books. IEEE Transactions on Signal Processing, Vol. 67, no. 11, pp. 3001-3012. doi: 10.1109/TSP.2019.2907260.
4. Ntakaris A., Magris M., Kannianen J., Gabbouj M., and Iosifidis A. (2018) Benchmark dataset for mid-price forecasting of limit order book data with machine learning methods. Journal of Forecasting, vol. 37, no. 8, pp. 852-866.
5. Hinton, G.E.; Srivastava, N.; Krizhevsky, A.; Sutskever, I.; Salakhutdinov, R.R. (2012) Improving Neural Networks by Preventing Co-Adaptation of Feature Detectors. arXiv, pp. 1207.0580.