

Научная статья
УДК 004.855.5
doi: 10.17223/19988605/70/9

Нейросетевое тестирование алгоритма разметки данных для классификации уровней поддержки и сопротивления на финансовых рынках

Марк Альбертович Хайров¹, Владимир Григорьевич Спицын²

^{1,2} *Национальный исследовательский Томский политехнический университет, Томск, Россия*

² *Национальный исследовательский Томский государственный университет, Томск, Россия*

¹ *mah9@tpu.ru,*

² *spvg@tpu.ru*

Аннотация. Представлен алгоритм разметки данных для обучения классификатора, способного определять уровни поддержки и сопротивления на данных финансовых рынков. На основе данных, полученных с помощью этого алгоритма, была обучена модель CNN-LSTM-MLP, включающая блок каузальных сверток, LSTM и полносвязные слои. Эксперимент с простой торговой стратегией продемонстрировал практическую применимость модели, сопровождавшуюся повышением доходности на 10% в сравнении с базовой стратегией, где модель не была использована.

Ключевые слова: данные рыночных котировок; глубинное обучение; причинно-следственная связь; уровни поддержки; уровни сопротивления.

Для цитирования: Хайров М.А., Спицын В.Г. Нейросетевое тестирование алгоритма разметки данных для классификации уровней поддержки и сопротивления на финансовых рынках // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2025. № 70. С. 91–102. doi: 10.17223/19988605/70/9

Original article
doi: 10.17223/19988605/70/9

Neural network testing of a data labeling algorithm for classifying support and resistance levels in financial markets

Mark A. Khairov¹, Vladimir G. Spitsyn²

^{1,2} *National Research Tomsk Polytechnic University, Tomsk, Russian Federation*

² *National Research Tomsk State University, Tomsk, Russian Federation*

¹ *mah9@tpu.ru*

² *spvg@tpu.ru*

Abstract. An algorithm for labeling data is presented to train a classifier capable of identifying support and resistance levels in financial market data. Using data obtained from this algorithm, a CNN-LSTM-MLP model was trained, incorporating causal convolutions, LSTM, and fully connected layers. An experiment with a simple trading strategy demonstrated the practical applicability of the model, accompanied by a 10% increase in profitability compared to a basic strategy where the model was not used.

Keywords: market quote data; deep learning; causal convolution; support levels, resistance levels.

For citation: Khairov, M.A., Spitsyn, V.G. (2025) Neural network testing of a data labeling algorithm for classifying support and resistance levels in financial markets. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naja tehnika i informatika – Tomsk State University Journal of Control and Computer Science*. 70. pp. 91–102. doi: 10.17223/19988605/70/9

Введение

Уровни поддержки и сопротивления являются ключевыми концепциями в техническом анализе финансовых рынков, обеспечивающими важные ориентиры для трейдеров и инвесторов.

Уровень поддержки – это ценовой уровень, на котором наблюдается усиление спроса на актив, достаточное для предотвращения дальнейшего снижения его цены. При достижении уровня поддержки цена актива, как правило, стабилизируется или начинает повышаться, поскольку покупатели вступают в рынок, считая цену привлекательной для покупки.

Уровень сопротивления, напротив, представляет собой ценовой уровень, на котором усиливается предложение актива, что препятствует дальнейшему росту его цены. На этом уровне продавцы начинают активно продавать актив, считая текущую цену выгодной для продажи, что приводит к стабилизации или снижению цены.

Уровни поддержки и сопротивления обладают некоторой предсказательной способностью, что было показано в работах С. Osler, F. Garzarelli, K. Chung и A. Bellotti [1–3]. При том что уровни поддержки и сопротивления используются на протяжении нескольких десятков лет практикующими инвесторами и трейдерами, в академической литературе еще не было представлено алгоритма разметки данных с целью обучения классификатора для предсказания уровней поддержки и сопротивления. К тому же у других авторов нет работ по построению моделей глубокого обучения для предсказания образования уровней поддержки и сопротивления.

С другой стороны, для задачи, частично схожей с определением уровней поддержки и сопротивления предсказанием по определению направления движения цены, существуют примеры успешно обученных нейросетевых классификаторов. Так, в работе J. Sirignano и R. Cont [4] была обучена модель LSTM, качество которой не менялось со временем, также позволявшая прогнозировать динамику цен для активов, которых не было в обучающей выборке. В работе Z. Zhang и соавт. [5] представлен пример построения классификатора с высокой точностью, которая не снижается во времени. Представленный классификатор состоял из сверточного блока, блока Inception [6] и блока LSTM. Как отмечают авторы, такая архитектура позволяет модели обучаться извлекать универсальные и наиболее важные признаки.

В настоящей работе впервые представлена методика разметки данных для обучения классификатора для детектирования уровней поддержки и сопротивления. С использованием данных, полученных при помощи разработанной методики разметки, были обучены классификаторы разного типа, такие как логистическая регрессия (LR), многослойный персептрон и LSTM. Для повышения качества классификаторов использовались карты признаков, сгенерированные при помощи специального модуля генерации признаков на основе одномерных каузальных сверток.

Было продемонстрировано возможность практического применения представленных методик на примере простейшей торговой симуляции.

1. Исходные данные

В настоящей работе используются данные о лучших ценах на продажу (best ask price, $a(t)$) и покупку (best bid price, $b(t)$) активов, а также соответствующие объемы имеющихся предложений на покупку и продажу активов.

Лучшая цена на продажу в момент времени t ($a(t)$) – это цена предложения о продаже, по которой возможно наиболее выгодно продать 1 ед. актива в момент времени t . Лучшая цена на покупку в момент времени t ($b(t)$) – это цена предложения о покупке, по которой возможно наиболее выгодно купить 1 ед. актива в момент времени t .

Объемами на продажу или покупку мы называем количество акций, которые можно продать или купить по предложенной цене.

В дальнейшем будет рассматриваться средняя цена $m(t) = \frac{a(t) + b(t)}{2}$, которая лежит между best bid и best ask.

Пример исходных данных

participant_timestamp	Цена на продажу (ask price)	Объем на продажу (ask volume)	Цена на покупку (bid price)	Объем на покупку (bid volume)
1674161999987619167	135,29	1	135,27	12
1674161999988218000	135,30	44	135,28	19
1674161999988468649	135,28	43	135,28	19
...	...	...	...	...

Для эксперимента были использованы данные о best bid и best ask ценах и объемах для акций AAPL, GE, MSFT и NVDA с 19 января 2023 г. по 22 мая 2023 г. В этом периоде было 83 торговых дня. Данные были получены от провайдера Polygon.io. В табл. 1 представлен пример данных из датасета.

2. Алгоритм разметки данных для обучения классификатора

Введем формальные определения для уровней поддержки и сопротивления, которые будут использоваться в алгоритме разметки данных.

Определение. Уровень поддержки в момент времени t определяется как цена $S_t = m(t) \pm \pi$, где $m(t)$ является локальным минимумом на интервале $[t-T, t+T]$, т.е. $m(t) \leq m(\tau) \pm \pi$ для любого $\tau \in [t-T, t+T]$.

Определение. Уровень сопротивления в момент времени t как цена $R_t = m(t) \pm \pi$, где $m(t)$ является локальным максимумом на интервале $[t-T, t+T]$, т.е. $m(t) \geq m(\tau) \pm \pi$ для любого $\tau \in [t-T, t+T]$.

Алгоритм разметки представляет собой последовательность шагов, направленных на автоматическое нахождение примеров для обучения классификатора. Задача классификатора состоит в том, чтобы среди потенциальных уровней поддержки и сопротивления отделить те уровни цен, которые образуют кластеры поддержки и сопротивления

Определение. Потенциальный уровень поддержки в момент времени t определяется как цена $PS_t = m(t) \pm \pi$, где $m(t)$ является локальным минимумом на интервале $[t-T, t]$, т.е. $m(t) \leq m(\tau) \pm \pi$ для всех $\tau \in [t-T, t]$.

Определение. Потенциальный уровень сопротивления в момент времени t определяется как цена $PR_t = m(t) \pm \pi$, где $m(t)$ является локальным максимумом на интервале $[t-T, t]$, т.е. $m(t) \geq m(\tau) \pm \pi$ для всех $\tau \in [t-T, t]$.

Определение. Кластер поддержки определяется как упорядоченная последовательность уровней поддержки $CS = (S_1, S_2, \dots, S_n)$, где каждому S_i соответствует время t_i из $t_1 < t_2 < \dots < t_n$, при этом для каждого $i = 1, 2, \dots, n$, $|S_i - S_1| \leq \pi$, для каждого $t \in [t_1, t_n]$ $m(t) \geq m(t_1) - \pi$ и $t_{i+1} - t_i \leq K$ для $i = 1, 2, \dots, n-1$.




Рис. 1. Кластеры поддержки и сопротивления: a – кластеры поддержки; b – кластеры сопротивления

Fig. 1. Support and resistance clusters: a – support clusters; b – resistance clusters

Определение. Кластер сопротивления определяется как упорядоченная последовательность уровней сопротивления $CR = (R_1, R_2, \dots, R_n)$, где каждому R_i соответствует время t_i из $t_1 < t_2 < \dots < t_n$, при этом для каждого $i = 1, 2, \dots, n$, $|R_i - R_1| \leq \pi$, для каждого $t \in [t_1, t_n]$ $m(t) \leq m(t_1) + \pi$ и $t_{i+1} - t_i \leq K$ для $i = 1, 2, \dots, n-1$.

На рис. 1 представлены примеры кластеров поддержки и сопротивления.

Таким образом упорядоченную последовательность кластеров поддержки можно обозначить как $((S_{i,j})_{j=1}^k)_{i=1}^n$, а упорядоченную последовательность кластеров сопротивления как $((R_{i,j})_{j=1}^k)_{i=1}^n$.

Для каждого i -го наблюдения производятся:

1. Нахождение уровней цены:
 - а. Для уровней поддержки:
 - i. Если цена m_t является локальным минимумом на интервале $[t-T, t]$, то это потенциальный уровень поддержки PS_t .
 - ii. Если потенциальный уровень поддержки PS_t является локальным минимумом на интервале $(t, t+T]$, то это уровень поддержки S_t .
 - б. Для уровней сопротивления:
 - i. Если цена m_t является локальным максимумом на интервале $[t-T, t]$, то это потенциальный уровень сопротивления PR_t .
 - ii. Если потенциальный уровень сопротивления PR_t является локальным максимумом на интервале $(t, t+T]$, то это уровень сопротивления R_t .
2. Разбиение уровней цены на кластеры:
 - а. Для уровней поддержки:
 - i. Если для уровня поддержки S_t существует уровень поддержки $S_{t'}$, где $t' \in [t-K, t]$, которому соответствует элемент кластера поддержки $S_{n,k} \in (S_{n,j})_{j=1}^k$, то проверяется, выполняется ли условие $|S_t - S_{n,1}| \leq \pi$:
 1. Если выполняется, то S_t добавляется в кластер CS_n .
 2. Если не выполняется, то S_t образует новый кластер CS_{n+1} .
 - б. Для уровней сопротивления:
 - i. Если для уровня сопротивления R_t существует уровень поддержки $R_{t'}$, где $t' \in [t-K, t]$, которому соответствует элемент кластера сопротивления $R_{n,k} \in (R_{n,j})_{j=1}^k$, то проверяется, выполняется ли условие $|R_t - R_{n,1}| \leq \pi$:
 1. Если выполняется, то R_t добавляется в кластер CR_n .
 2. Если не выполняется, то R_t образует новый кластер CR_{n+1} .

3. Методы исследования

Далее детально рассмотрены методы исследования, в частности процесс подготовки данных, модели, используемые в экспериментах, их обучение, а также простой торговый алгоритм и его версия с использованием фильтра на основе глубокого обучения

3.1. Подготовка данных для обучения моделей

Задача детектирования уровней поддержки и сопротивления была сведена к задаче классификации по трем классам:

- нейтральный класс – множества потенциальных уровней поддержки и сопротивления, при этом не являющихся ни уровнями поддержки, ни уровнями сопротивления;

- кластер уровней сопротивления;
- кластер уровней поддержки.

Для моделирования экспериментов были отобраны данные NBBO по четырём активам AAPL, MSFT, GE и NVDA за период с 26.01.2023 по 22.05.2023 (78 дней). Такие данные содержат лучшие цены на продажу $a(t)$ и покупку $b(t)$ активов, а также их объёмы – $v_a(t)$ и $v_b(t)$.

В обучающую выборку вошли первые 40 дней (с 26.01.2023 по 23.04.2023), для валидационной выборки было выделено 15 дней (с 24.03.2023 по 14.04.2023), для тестовой был выделен 1 месяц, или 23 торговых дня (с 17.04.2023 по 17.05.2023). Соотношение дней в выборках иллюстрировано на рис. 2.




Рис. 2. Разделение исходных данных на выборки:

Train – обучающая (40 дней), Validation – валидационная (15 дней), Test – тестовая (23 дня)

Fig. 2. Dataset partitioning in:

Train – train set (40 days), Validation – validation set (15 days), Test – test set (23 days)

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

Параметр T был установлен как 1 600, так как из-за неоднородной плотности событий и флуктуаций цены при значениях $T < 1\,600$ во многих случаях паттерн образования локальных максимумов воспринимается человеком с трудом (по крайней мере на малых выборках). Значение параметра K было принято равным 1 600.

Обучающая, валидационная и тестовая выборки были сбалансированы при помощи приведения числа примеров в каждом из дней по каждому из классов к числу примеров наименьшего из классов в отдельно взятый день. В табл. 2 представлено количество примеров в каждой из выборок по каждому из классов.

Таблица 2

Количество примеров в каждом из классов в каждой из выборок

Выборка	Количество примеров
Обучающая	116 172
Валидационная	30 162
Тестовая	39 663

Входной тензор имел вид: $X = [x_1, x_2, \dots, x_i, \dots, x_{400}]^T \in \mathbb{R}^{400 \times 4}$, где $x_i = [a_i, v_{a,i}, b_i, v_{b,i}]$. Значение 400 соответствует количеству наблюдений, используемых для осуществления предсказаний, а 4 – количеству признаков.

К признакам к каждому из дней по отдельности была применена процедура стандартизации при помощи z-score (1), средние значения по каждому из признаков $\bar{x}$ и стандартные отклонения σ рассчитывались по пяти предшествующим дням [5, 7]:

$$z_i = \frac{x_i - \bar{x}}{\sigma} \quad (1)$$

где $\bar{x}$ – вектор средних значений; σ – вектор стандартных отклонений.

3.2. Архитектуры моделей, задействованных в эксперименте

С целью получения более полного представления о характере зависимостей уровней поддержки и сопротивления от истории цен рассматривается ряд моделей, имеющих различные функции преобразования сигнала.

В работе рассматриваются такие архитектуры глубоких нейронных сетей, как многослойный перцептрон (MLP) и гибридная искусственная нейронная сеть LSTM-MLP, которая совмещает блоки LSTM и несколько полносвязных слоев. Также рассматривается логистическая регрессия (LR) с целью проверить, позволит ли переход к нелинейным моделям осуществить прирост качества, и если позволит, то насколько существенным будет такой эффект.

Генерация дополнительных признаков может позволить улучшить производительность модели за счет извлечения каких-либо сложных зависимостей. Признаки могут быть сгенерированы с использованием знаний о предметной области, и в качестве признаков могут быть применены, например, технические и количественные индикаторы [8] или эконометрические признаки [7, 8]. Также с целью автоматического извлечения признаков могут использоваться обучаемые блоки генерации признаков. Например, известно, что для автоматического извлечения признаков подходят сверточные нейронные сети [10].

В работе в качестве блока автоматической генерации признаков используются блоки каузальных сверточных сетей [7, 11, 12]. Каузальные свертки позволяют сохранять порядок элементов последовательности.

На рис. 3 представлены архитектуры разработанных моделей с использованием CNN-блоков.




Рис 3. Архитектуры моделей: a – CNN-LSTM-MLP, b – CNN-MLP, c – CNN-LR

Fig. 3. Model's architectures: a) CNN-LSTM-MLP, b) CNN-MLP, c) CNN-LR

Таким образом, представлен ряд моделей по возрастанию их сложности, или «гибридности», с целью оценить эффект влияния каждого из блоков (CNN, MLP и LSTM) на показатели качества. В итоге производится обучение и тестирования следующих моделей:

- LR;
- MLP;
- LSTM-MLP;
- CNN-LR;
- CNN-MLP;
- CNN-LSTM-MLP.

3.3. Процесс обучения

Обучение моделей производилось при помощи стохастического градиентного спуска. В качестве функции потерь использовалась кросс-энтропия. Обучение останавливалось, когда точность (accuracy) на валидационной выборке не повышалась более чем на 0,01% в течении 20 эпох.

3.4. Торговые стратегии

С целью проверки целесообразности практического применения разработанных методик и алгоритмов в работе проводятся тестирование торговой стратегии и измерение влияния предсказаний классификатора на ее эффективность.

Алгоритм, принимающий решения о покупке / продаже активов, наблюдает за двумя событиями: появлением потенциального уровня сопротивления / поддержки и его подтверждением.

Событием подтверждения уровня поддержки мы считаем такое событие, произошедшее в момент t , когда средняя цена пересекла верхнюю границу области поддержки $m(t) > \bar{S}$.

Событием подтверждения уровня сопротивления мы считаем такое событие, произошедшее в момент t , когда средняя цена пересекла нижнюю границу области сопротивления $m(t) < \underline{R}$.

Симуляция торговли осуществляется по следующему алгоритму:

1. Определяется потенциальный уровень поддержки / сопротивления.
2. Осуществляется классификация выбранного наблюдения (к одному из 3 классов).
3. Фиксируется событие подтверждения уровня поддержки / сопротивления.
4. Если уровень поддержки / сопротивления был подтвержден, то осуществляется покупка / продажа актива соответственно.

4.1. Ожидается появление потенциального уровня поддержки и последующее его подтверждение, после чего происходит покупка актива.

4.2. После покупки актива ожидается событие появления потенциального уровня сопротивления и его подтверждения, при этом рассматриваются только уровни сопротивления, в которых цена на продажу выше цены на покупку уровня поддержки из (4.1).

В качестве расширения этой стратегии использовался дополнительный фильтр наблюдений, являющихся потенциальными уровнями поддержки / сопротивления, на основе модели глубокого обучения (Deep Learning Filter, DLF).

В случаях когда модель не классифицирует потенциальный уровень поддержки / сопротивления в соответствии с его предполагаемым классом, в дальнейшем такой уровень поддержки / сопротивления исключается из рассмотрения даже в случае появления события подтверждения для этого потенциального уровня поддержки / сопротивления.

Алгоритм симуляции торговли имеет ряд серьезных допущений:

1. Покупка и продажа осуществляются в момент, когда заявка на продажу / покупку была опубликована, по цене, указанной в заявке.

2. Действия торгового алгоритма никаким образом не влияют на цены и объемы купли / продажи.
3. Комиссия брокера составляет \$0.

3.4.1. Метрики оценки торговой стратегии

В качестве метрик качества используемой торговой стратегии используются как процент прибыли, так и коэффициент Шарпа, который позволяет оценить торговую стратегию с учетом волатильности.

Коэффициент Шарпа был рассчитан следующим образом:

1. Определяется прибыль от торговой стратегии в процентах:

$$\text{Daily Return Percentage} = \frac{\text{Daily Profit}}{\text{Starting Capital of the Day}}, \quad (2)$$

2. Пересчитывается дневная ставка инвестиционной стратегии с низким риском:

$$\text{Daily Risk - Free Rate} = (1 + \text{Anual Risk - Free Rate})^{\frac{1}{252}} - 1, \quad (3)$$

3. Рассчитывается избыточная прибыль за день:

$$\text{Excess Return} = \text{Daily Return Percentage} - \text{Daily Risk - Free Rate}, \quad (4)$$

4. Рассчитывается усредненное значение избыточной прибыли,

5. Вычисляется дневное значение коэффициента Шарпа:

$$\text{Daily Sharpe Ratio} = \frac{\text{Average Excess Return}}{\text{Standard Deviation of Return}}, \quad (5)$$

6. На основе дневного значения коэффициента Шарпа оценивается, каким может быть годовое значение метрики (предполагается, что в году 252 торговых дня):

$$\text{Anualized Sharpe Ratio} = \text{Daily Sharpe Ratio} \times \sqrt{252}. \quad (6)$$

В качестве инвестиционной стратегии с низким риском используются краткосрочные казначейские векселя США за год.

Стартовый капитал в начале каждого дня пересчитывается в соответствии с прибылями и потерями от предыдущих дней.

4. Исследование классификаторов, обученных при помощи алгоритма

В разделе представлены результаты обучения и тестов моделей, а также результаты тестирования торговой стратегии с использованием дополнительного фильтра наблюдений DLF и без его применения.

4.1. Результаты обучения моделей

В табл. 3 представлены результаты тестирования моделей. Из табл. 3 видно, что наилучшие результаты показала модель типа CNN-LSTM-MLP.

Таблица 3

Метрики, полученные на тестовой выборке

Модель	Accuracy	Precision	Recall	F1
LR	66,15	64,20	66,15	63,07
MLP	68,56	67,41	68,56	67,51
LSTM-MLP	67,59	68,07	67,59	67,76
CNN-LR	70,89	69,46	70,87	68,77
CNN-MLP	70,69	70,40	70,69	70,29
CNN-LSTM-MLP	75,98	75,62	75,98	75,73

На рис. 4 представлены матрицы ошибок для всех моделей, где можно видеть распределение предсказаний наблюдений в тестовой выборке по классам. Из рис. 4 и табл. 3 можно заключить, что модели, имевшие блок генерации признаков на основе каузальных сверток, продемонстрировали более высокие результаты в сравнении с моделями без CNN-блоков.




Рис 4. Матрицы ошибок, полученные на тестовой выборке:
 a – CNN-LSTM-MLP, b – CNN-MLP, c – CNN-LR, d – LSTM-MLP, e – MLP, f – LR
 Fig. 4. Confusion matrix for the training set:
 a) CNN-LSTM-MLP, b) CNN-MLP, c) CNN-LR, d) LSTM-MLP, e) MLP, f) LR

Также из рис. 4 видно, что наибольшее количество ошибок связано с классификацией нейтрального класса. Суммарное количество ошибок первого и второго рода возрастает на матрицах ошибок как на рис. 4, a и 4, b, так и на рис. 4, d и 4, f, что может говорить о том, что глубокая архитектура, в частности несколько полносвязных слоев вместе с анализом временных зависимостей при помощи LSTM, позволяют с большей точностью классифицировать наблюдения верно. Кроме того, даже в случае CNN-LSTM-MLP (см. рис. 4, a) количество ложноположительных и ложноотрицательных предсказаний для нейтрального класса существенно, при этом классификаторы могут в сравнении точно отделить друг от друга классы уровней поддержки и сопротивления. Таким образом, можно предположить, что представленные определения потенциальных уровней поддержки и сопротивления не всегда обеспечивают точное разграничение между этими уровнями. Например, возможна ситуация, когда имеется два последовательных наблюдения, находящихся близко друг к другу, где одно наблюдение было определено только как потенциальный уровень поддержки или сопротивления, а последующее было определено как наблюдение, образующее кластер поддержки или сопротивления. В крайнем случае два таких наблюдения могут идти в том числе и подряд друг за другом.

4.2. Результаты тестирования торговых стратегий

Алгоритмы торговых стратегий, представленных в разд. 3.4, были применены к данным тестовой выборки. Была осуществлена торговля как с фильтром DLF, так и без него. Для фильтрации наблюдений применялась обученная модель CNN-LSTM-MLP, показавшая наиболее высокие результаты.

К активам из тестовой выборки был добавлен дополнительный актив TSLA, которого ранее не было в обучающей и валидационной выборках.

На каждый из используемых активов было выделено 6 000 долларов США стартового капитала. В качестве инвестиционной стратегии с низким риском был взят вексель казначейства США со сроком погашения в 52 недели. Предполагалось, что вексель номиналом 30 000 долларов был взят по скидке в 4,61% 17.04.2023 [13]. Таким образом, доход от векселя определяется как

$$\text{Treasury Bond Return} = \frac{\text{Face Value} - \text{Purchased Price}}{252}, \quad (7)$$

где *Face Value* – номинальная стоимость ценной бумаги; *Purchased Price* – стоимость покупки ценной бумаги.

Ежедневный доход от стратегии с низким риском рассчитывался как

$$\text{Daily Risk - Free Rate} = \frac{\text{Treasury Bond Return}}{252}. \quad (8)$$

Результаты тестирования торговой стратегии представлены в табл. 4.

Таблица 4

Результаты тестирования торговой стратегии

	Средняя дневная доходность (в долларах США)		Абсолютное значение доходности за весь период (в долларах США)		Среднесуточный коэффициент Шарпа		Годовой коэффициент Шарпа	
	Без DLF	DLF	Без DLF	DLF	Без DLF	DLF	Без DLF	DLF
Акция								
AAPL	0,46	0,48	10,57	11,44	-1,80	-1,63	-28,51	-25,82
GE	0,31	0,32	7,12	7,38	-3,70	-3,47	-58,67	-55,15
MSFT	1,20	1,28	27,58	29,40	0,10	0,20	1,53	3,23
NVDA	2,02	2,34	46,42	53,96	0,27	0,31	4,36	4,92
TSLA	1,38	1,48	31,72	34,15	0,24	0,33	3,86	5,28
Итог по всему портфелю								
	5,37	5,92	123,41	136,32	–	–	-0,74	1,22

Таким образом, использование DLF позволило увеличить общую прибыль по портфелю на 10,46%, а также получить более высокое значение коэффициента Шарпа и превратить невыгодную стратегию в выгодную с приемлемым отношением избыточной прибыли к величине риска (считается, что коэффициент Шарпа 1 и более является приемлемым для инвестиционной стратегии [14]).

Для акций AAPL и GE коэффициент Шарпа принимает отрицательные значения, что значит, что отдельно для каждого из этих двух символов торговая стратегия проигрывает по доходности инвестиционной стратегии с низким риском. Такой результат можно объяснить несовершенством выбранной торговой стратегии, так как после покупки актива ожидается появление более выгодной цены, что может случиться через значительное время или чего может не случиться вообще при общем нисходящем тренде на рынке.

Заключение

В работе предложена методика разметки для обучения классификатора с целью детектирования уровней поддержки и сопротивления. Показана возможность практического применения разработанной методики посредством использования обученных моделей в торговой симуляции.

Наиболее высоких результатов удалось достичь на основе модели типа CNN-LSTM-MLP, при помощи совмещения блоков CNN, LSTM и полносвязных слоев, т.е. глубокой искусственной нейронной сети, что может говорить о существовании нелинейной зависимости между историей цен и явлением образования уровней поддержки и сопротивления.

Можно также отметить, что логистическая регрессия продемонстрировала результат F1-метрики ~ 63%, что уже нельзя назвать случайным результатом. Из этого можно предположить, что данную методику возможно применять не только для глубокого обучения.

В качестве развития методики разметки для уровней поддержки и сопротивления можно предложить разработать понятия, которые позволят более четко разграничить уровни поддержки / сопротивления и наблюдения, которые не являются ни уровнями поддержки, ни уровнями сопротивления (нейтральный класс).

Список источников

1. Osler C. L. Support for resistance: technical analysis and intraday exchange rates // *Economic Policy Review*. 2000. V. 6 (2). P. 53–68.
2. Garzarelli F. et al. Memory effects in stock price dynamics: evidences of technical trading // *Scientific Reports*. 2014. V. 4 (1). Art. 4487. doi: 10.1038/srep04487
3. Chung K., Bellotti A. Evidence and Behaviour of Support and Resistance Levels in Financial Time Series // *arXiv preprint*. 2021. doi: 10.48550/arXiv.2101.07410. URL: <https://arxiv.org/abs/2101.07410> (accessed: 05.12.2024).
4. Sirignano J., Cont R. Universal features of price formation in financial markets: perspectives from deep learning // *Quantitative Finance*. 2019. V. 19 (9). P. 1449–1459. doi: 10.1080/14697688.2019.1622295
5. Zhang Z., Zohren S., Roberts S. Deeplob: Deep convolutional neural networks for limit order books // *IEEE Transactions on Signal Processing*. 2019. V. 67 (11). P. 3001–3012. doi: 10.1109/tsp.2019.2907260
6. Szegedy C. et al. Going deeper with convolutions // *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015. P. 1–9. doi: 10.1109/cvpr.2015.7298594
7. Tsantekidis A. et al. Using deep learning for price prediction by exploiting stationary limit order book features // *Applied Soft Computing*. 2020. V. 93. Art. 106401. doi: 10.1016/j.asoc.2020.106401
8. Ntakaris A. et al. Mid-price prediction based on machine learning methods with technical and quantitative indicators // *PloS One*. 2020. V. 15 (6). e0234107. doi: 10.1371/journal.pone.0234107
9. Ntakaris A. et al. Feature engineering for mid-price prediction with deep learning // *IEEE Access*. 2019. V. 7. P. 82390–82412. doi: 10.1109/ACCESS.2019.2924353
10. LeCun Y. et al. Gradient-based learning applied to document recognition // *Proc. of the IEEE*. 1998. V. 86 (11). P. 2278–2324. doi: 10.1109/5.726791
11. Wallbridge J. Transformers for limit order books // *arXiv preprint*. 2020. doi: 10.48550/arXiv.2003.00130. URL: <https://arxiv.org/abs/2003.00130> (accessed: 05.12.2024).
12. Van Den Oord A., Dieleman S., Zen H., Simonyan K., Vinyals O., Graves A., Kalchbrenner N., Senior A., Kavukcuoglu K., Wavenet: A generative model for raw audio // *arXiv preprint*. 2020. doi: 10.48550/arXiv.1609.03499. URL: <https://arxiv.org/abs/1609.03499> (accessed: 05.12.2024).
13. Daily Treasury Bill Rates // U.S. Department of the Treasury. URL: https://home.treasury.gov/resource-center/data-chart-center/interest-rates/TextView?type=daily_treasury_bill_rates&field_tdr_date_value=2023 (accessed: 05.12.2024).
14. Maverick J.B. What the Sharpe Ratio Means for Investors // *Investopedia*. URL: <https://www.investopedia.com/ask/answers/010815/what-good-sharpe-ratio.asp> (accessed: 05.12.2024).

References

1. Osler, C.L. (2000) Support for resistance: technical analysis and intraday exchange rates. *Economic Policy Review*. 6(2). pp. 53–68.
2. Garzarelli, F. et al. (2014) Memory effects in stock price dynamics: evidences of technical trading. *Scientific Reports*. 4(1). Art. 4487. DOI: 10.1038/srep04487
3. Chung, K. & Bellotti, A. (2021) Evidence and Behaviour of Support and Resistance Levels in Financial Time Series. *arXiv preprint arXiv:2101.07410*. DOI: 10.48550/arXiv.2101.07410
4. Sirignano, J. & Cont, R. (2019) Universal features of price formation in financial markets: perspectives from deep learning. *Quantitative Finance*. 19(9). pp. 1449–1459. DOI: 10.1080/14697688.2019.1622295
5. Zhang, Z., Zohren, S. & Roberts, S. (2019) Deeplob: Deep convolutional neural networks for limit order books. *IEEE Transactions on Signal Processing*. 67(11). p. 3001–3012. DOI: 10.1109/tsp.2019.2907260
6. Szegedy, C. et al. (2015) Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*. pp. 1–9. DOI: 10.1109/cvpr.2015.7298594
7. Tsantekidis, A. et al. (2020) Using deep learning for price prediction by exploiting stationary limit order book features. *Applied Soft Computing*. 93. pp. 106401. DOI: 10.1016/j.asoc.2020.106401
8. Ntakaris, A. et al. (2020) Mid-price prediction based on machine learning methods with technical and quantitative indicators. *Plos one*. 15(6). pp. e0234107. DOI: 10.1371/journal.pone.0234107
9. Ntakaris, A. et al. (2019) Feature engineering for mid-price prediction with deep learning. *Ieee Access*. 7. pp. 82390–82412. DOI: 10.1109/ACCESS.2019.2924353
10. LeCun, Y. et al. (1998) Gradient-based learning applied to document recognition. *Proceedings of the IEEE*. 86(11). pp. 2278–2324. DOI: 10.1109/5.726791
11. Wallbridge, J. (2020) Transformers for limit order books. *arXiv preprint arXiv:2003.00130*. DOI: 10.48550/arXiv.2003.00130

12. Van Den Oord, A., Dieleman, S., Zen, H., Simonyan, K., Vinyals, O., Graves, A., Kalchbrenner, N., Senior, A. & Kavukcuoglu, K. (2016) Wavenet A generative model for raw audio. *arXiv preprint* arXiv:1609.03499. DOI: 10.48550/arXiv.1609.03499
13. U.S. Department of the Treasury. (n.d.) *Daily Treasury Bill Rates*. [Online] Available from: https://home.treasury.gov/resource-center/data-chart-center/interest-rates/TextView?type=daily_treasury_bill_rates&field_tdr_date_value=2023 (Accessed: 5th December 2024).
14. Maverick, J.B. (2024) *What the Sharpe Ratio Means for Investors*. [Online]. Available from: <https://www.investopedia.com/ask/answers/010815/what-good-sharpe-ratio.asp> (Accessed: 5th December 2024).

Информация об авторах:

Хайров Марк Альбертович – аспирант отделения информационных технологий Инженерной школы информационных технологий и робототехники Национального исследовательского томского политехнического университета (Томск, Россия). E-mail: mah9@tpu.ru

Спицын Владимир Григорьевич – доктор технических наук, профессор отделения информационных технологий Инженерной школы информационных технологий и робототехники Национального исследовательского томского политехнического университета; профессор Национального исследовательского Томского государственного университета (Томск, Россия). E-mail: spvg@tpu.ru

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Information about the authors:

Khairov Mark A. (Post-graduate Student, Information Technology Department, School of Information Technology and Robotics Engineering, National Research Tomsk Polytechnic University, Tomsk, Russian Federation). E-mail: mah9@tpu.ru

Spitsyn Vladimir G. (Doctor of Technical Sciences, Professor, Information Technology Department, School of Information Technology and Robotics Engineering, National Research Tomsk Polytechnic University; National Research Tomsk State University, Tomsk, Russian Federation, Tomsk, Russian Federation). E-mail: spvg@tpu.ru

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.

Поступила в редакцию 29.10.2024; принята к публикации 03.03.2025

Received 29.10.2024; accepted for publication 03.03.2025