

СЕКЦИЯ 6

ИНФОРМАЦИОННЫЕ СИСТЕМЫ

АНАЛИЗА ДАННЫХ

Л. Г. РЕШЕТНИКОВА, М. С. ЦЫГАНОВА

Тюменский государственный университет, г. Тюмень

УДК 004.94

СИСТЕМА ПОДДЕРЖКИ ИНВЕСТИЦИОННЫХ РЕШЕНИЙ НА ФИНАНСОВОМ РЫНКЕ

Аннотация. В статье представлена система поддержки принятия решений при портфельном инвестировании в акции на Московской бирже. На реальных биржевых данных обучена рекуррентная нейронная сеть архитектуры LSTM; инвестиционные рекомендации генерирует сравнительный блок системы. По данным за 2014-2023 гг. система показала прирост капитала 229.9% против 45.8% прироста индексного портфеля Мосбиржи¹⁰.

Ключевые слова: инвестиции, система поддержки принятия решений, рекуррентная нейронная сеть (RNN), архитектура LSTM, управление портфелем акций.

Введение. Финансовый рынок является важным элементом экономической системы. Реализация Стратегии повышения финансовой грамотности в Российской Федерации на 2017-2023 годы (утв. Распоряжением правительства РФ 25.09.2017 № 2039-р), приводит к тому, что на финансовом рынке появляется много частных инвесторов. В России доля частных инвесторов составляет около 15% взрослого населения. В начале мая 2023 г. Московская биржа объявила о росте количества частных инвесторов. По итогам апреля 2023 г. значение достигло 25,1 млн клиентов. Доля физических лиц в объеме торгов акциями в апреле 2023 г. составила 81,5% — новое рекордное значение, прошлый максимум зафиксирован в феврале 2023 г. — 81,1%. Доля физических лиц в объеме торгов облигациями в апреле 2023 г. составила 36,5% [1].

Стимулом для частного инвестора выступает прибыль, как положительная разница между ценой продажи и ценой покупки финансовых активов (акций), возникающая из-за изменения рыночной цены при удержании акций определенный период времени. Поэтому точное прогнозирование цен на акции играет важную роль в инвестировании. Поскольку данные о ценах на акции характеризуются высокой частотой, волатильностью, нелинейностью и длительной памятью, точное прогнозирование цен на акции является сложной задачей.

Исследованию различных методов прогнозирования динамики цен фондовых инструментов посвящено множество научных публикаций. Традиционные эконометрические методы, такие как ARIMA, GARCH и другие, показывают лучшие результаты прогнозирования при менее изменчивых данных [2; 3; 4]. Традиционные алгоритмы машинного обучения, такие как случайный лес (RF) и метод опорных векторов (SVM), могут быть хорошим выбором для изучения нелинейных взаимосвязей между ценой акций и различными влияющими факторами. Тем не менее, эти методы чрезмерно полагаются на отбор выборок при построении модели, что делает построение и обновление модели негибкими, в результате чего точность прогнозирования не всегда соответствует требованиям [5; 6]. Модели глубокого обучения обладают более мощными возможностями обучения и самоадаптации, чем традиционные модели машинного обучения, и могут лучше выполнять анализ цен на акции [7].

Анализ публикаций, где применяются модели глубокого обучения для прогнозирования цен акций показал, что для решения данной задачи применялось множество различных типов и архитектур искусственных нейронных сетей (ИНС): рекуррентные нейронные сети (RNN), сверточные нейронные сети (CNN), нейронные сети с долговременной кратковременной памятью (LSTM) и их варианты и т. д. Кроме того, исследователи тестируют разные комбинации методов прогнозирования [8]. Каждый метод достигает определенного уровня точности, но также имеет свои ограничения.

Проблема исследования. Невысокий уровень финансовой грамотности частных инвесторов, а также психологические искажения

и отсутствие дисциплины приводят к отрицательным результатам и разочарованию в инвестициях. Решение указанной проблемы может быть связано с реализацией автоматизированной системы поддержки принятия инвестиционных решений на основе прогнозирования цен финансовых активов (акций) и их интерпретации, результатом работы которой будет инвестиционная рекомендация.

Целью данной работы является повышение эффективности портфельного инвестирования на российском фондовом рынке путем разработки системы поддержки принятия правильных инвестиционных решений.

Для достижения поставленной цели сформулирован комплекс задач, подлежащих решению:

- разработка общей архитектуры системы;
- построение и обучение модели прогнозирования цен акций;
- реализация алгоритма интерпретации полученного результата

в инвестиционную рекомендацию: включить акцию в инвестиционный портфель (купить) / исключить акцию из инвестиционного портфеля (продать).

В качестве показателей эффективности/качества системы поддержки инвестиционных решений рассматриваются: а) прирост инвестированного капитала в течение анализируемого периода; б) средняя годовая доходность инвестиционного портфеля; в) риск инвестиционного портфеля; г) значение коэффициента Шарпа.

Указанные показатели сравниваются с такими же показателями эталонного индексного инвестиционного портфеля; в качестве эталона вступает индекс Московской биржи (MOEX10).

Материалы и методы. Поиск компромисса между эффективностью и затратами ресурсов на прогнозирование цен акций привел к выбору модели прогнозирования на основе рекуррентной нейронной сети архитектуры LSTM [9]. По сравнению с традиционной RNN, модель LSTM обладает характеристиками, подходящими для обработки и прогнозирования важных событий с большими интервалами и задержками во временных рядах [10; 11; 12]. Так, в работе [13] предложена модель RNN на основе LSTM для прогнозирования ценового тренда акций GOOGL и NIKE, и результаты тестирования подтвердили ее эффективность.

В данном исследовании модель LSTM использовалась для прогнозирования значений индекса Московской биржи (MOEX10). Индекс Мосбиржи является основным индексом российского фондового рынка. Для вычислительных экспериментов использовались данные индекса Московской биржи 10 наиболее ликвидных акций за период с 6 января 1998 года по 08 мая 2023 года, в общей сложности 6329 торговых дней, и данные 10 акций, на основе которых рассчитывается этот индекс за период с 25 марта 2013 года по 08 мая 2023 года, в общей сложности 2546 торговых дней.

Построение и обучение модели выполнялось в среде программирования Google Colab на языке программирования Python. Для получения биржевых данных использована библиотека Pandas, класс `pandas_datareader.moex.MoexReader()`. Получаемый фрейм данных содержит 17 столбцов разной информации об акциях, обращающихся на Мосбирже, которые указаны в запросе. Параметры для обучения модели, включают ежедневные исторические цены открытия и цены закрытия, максимальную и минимальную цены, объем торгов. Описание исходного набора данных представлено в табл. 1.

Таблица 1

Набор биржевых данных для обучения модели

| <i>Показатель</i> | <i>Описание</i> | <i>Тип данных</i> |
|-------------------|------------------------------------|-------------------|
| OPEN | Цена открытия торгового дня | Число |
| CLOSE | Цена закрытия торгового дня | Число |
| HIGH | Максимальная цена за торговый день | Число |
| LOW | Минимальная цена за торговый день | Число |
| VOLUME | Объем сделок за торговый день | Число |

Набор данных характеризуется большим разбросом значений. Чтобы устранить влияние масштаба, набор данных был нормализован. Нормализация полезна для ускорения сходимости алгоритма оптимизации и предотвращения «взрыва градиента» при обучении сети. Данные были нормализованы на $[0, 1]$ с использованием нормализации Min-Max; расчетная формула имеет вид:

$$x_i^* = \frac{x_i - x_{min}}{x_{max} - x_{min}}, \quad (1)$$

где x_i — исходные данные; x_{min} — минимальное значение исходных данных; x_{max} — максимальное значение исходных данных; x_i^* — нормализованное значение.

Применение модели прогнозирования к масштабированным данным приводит к тому, что и получаемый результат также будет представлять собой масштабированное значение. Поэтому необходимо выполнить приведение выходных данных модели к первоначальному масштабу с помощью триггерного процесса. Расчетная формула имеет вид:

$$\hat{y}_i = \hat{y}_i^* \cdot (x_{max} - x_{min}) + x_{min}, \quad (2)$$

где \hat{y}_i^* — нормализованный прогноз цен на акции; \hat{y}_i — прогнозное значение цены акций, после приведения к первоначальному масштабу.

Работа с временным рядом, как последовательностью наблюдений во времени, требует особого подхода к прогнозированию. В случае неупорядоченных по времени (или другому признаку) данных для перекрестной проверки в процессе обучения модели, а также для проверки качества обученной модели выбирается случайное подмножество данных. Во временных рядах в качестве проверочного набора всегда должны использоваться «более поздние» данные по отношению к тем наблюдениям, на которых обучалась модель. Существует две схемы разделения данных временного ряда на обучающую и тестовую выборки: «скользящее окно» (sliding window) и «прямая цепочка» (forward chaining). В данном исследовании для разделения данных временного ряда на обучающую и тестовую выборки и при обучения модели использована схема «скользящего окна» (sliding window). Соотношение данных, используемых для обучающего набора и набора тестов составляет 8:2.

При построении модели использовалась стратегия прямого одноступенчатого прогнозирования. Для изучения внутренней модели динамических изменений слой LSTM обучается на биржевых данных. Затем выходные данные пропускаются через полносвязный слой. Начальная архитектура модели показана на рис. 1.

↳ Model: "sequential"

| Layer (type) | Output Shape | Param # |
|----------------|--------------|---------|
| LSTM (LSTM) | (None, 20) | 1760 |
| Output (Dense) | (None, 1) | 21 |

=====
Total params: 1,781
Trainable params: 1,781
Non-trainable params: 0
=====

Рис. 1. Начальная архитектура модели

Изначально слой LSTM содержал 20 нейронов, для обучения модели был использован оптимизатор RMSprop. Этот оптимизатор поддерживает скользящее (дисконтированное) среднее значение квадрата градиентов и делит градиент на корень из этого среднего. Реализация RMSprop использует обычный импульс, а не импульс Нестерова. В качестве функции потерь выбрана среднеквадратичная ошибка (RMSE), подходящая для задачи регрессии. Она рассчитывается с помощью следующей формулы:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2}, \quad (3)$$

где y'_i — прогнозируемая стоимость акций на i момент времени; y_i — реальная стоимость акций на i момент времени; n — общее количество наблюдений в выборке.

С точки зрения практического использования модели прогнозирования важно принятие правильного инвестиционного решения; критерием «правильности» является положительный финансовый результат. В рамках данного исследования была сформулирована гипотеза: принятие инвестиционного решения на основе высокоточного прогноза цены акции приводит к положительному финансовому результату.

Рекомендация относительно инвестиционного решения формируется следующим образом. Фактическая цена MOEX10 и прогнозное значение MOEX10 после приведения к первоначальному масштабу поступают в сравнительный блок. Генерация инвестиционной рекомендации о включении ценной бумаги в портфель (покупке) происходит при выполнении условия

$$(P_{t+1} - C_t) > 0, \quad (4)$$

где P — прогнозная цена; C — текущая цена; t — торговый день.

В случае невыполнения условия (4) система дает рекомендацию исключить ценную бумагу из портфеля (продать).

Последовательная реализация предварительной обработки биржевых данных, прогнозирования цены с помощью сети LSTM и генерации инвестиционной рекомендации с помощью сравнительного блока формирует систему поддержки принятия инвестиционных решений, представленную на рис. 2.

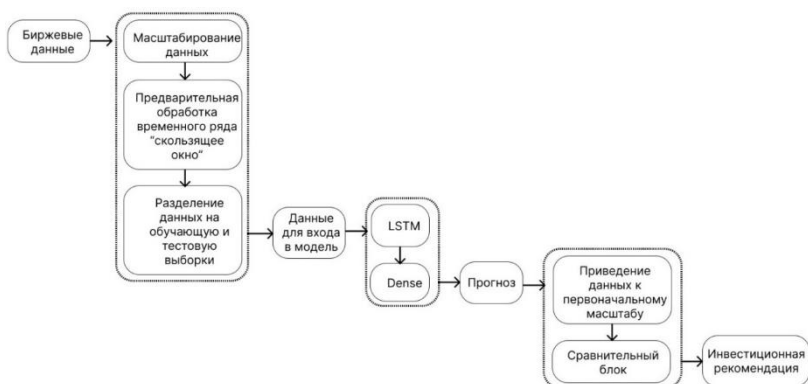


Рис. 2. Схема поддержки принятия инвестиционных решений на финансовом рынке

Результаты. Модель прогнозирования цены акций обучалась в течение 500 эпох, размер батча был выбран равным 20. При обучении использовался механизм ранней остановки (контроль качества модели в процессе обучения и прекращение обучения, когда ошибка

не уменьшается в течение нескольких эпох). Это позволяет предотвратить переобучение и сэкономить затраты ресурсов. Обученная модель показала ошибку прогноза RMSE 0.0128 на тестовой выборке.

Для изучения возможности оптимизации модели проводились вычислительные эксперименты по сетке параметров. Поскольку модель при первоначальных параметрах показала хорошие результаты, целью стало сохранение точности прогноза при сокращении затрат вычислительных ресурсов. В итоговой модели слой LSTM содержит 5 нейронов с оптимизатором Nadam, функцией ошибки RMSE. Обучение модели происходит 150 эпох с размером батча, равным 11, с контрольной точкой после 5 эпох и ранней остановкой при отсутствии улучшения контролируемого показателя после 15 эпох. На тестовых данных ошибка прогноза модели с указанными параметрами составила 0.0127.

Динамика фактического и прогнозируемого индекса Мосбиржи10 представлена на рис. 3.



Рис. 3. Динамика индекса Мосбиржи10 (факт и прогноз)

Вычислительные эксперименты показали, что принятие инвестиционных решений на основе прогноза цены, сгенерированного нейронной сетью, приводит к положительному финансовому результату. Такая инвестиционная стратегия повышает эффективность инвестирования в сравнении с эталонной индексной стратегией

инвестирования «купи и держи». Прирост капитала, инвестированного согласно рекомендациям за анализируемый период составил 229.9% против 45.8% прироста индексного портфеля Мосбиржи10.

Изменение стоимости индексного портфеля МОЕХ10 (красная линия) и портфеля из акций, входящих в этот индекс, управляемого в соответствии с инвестиционными рекомендациями системы (синяя линия) показано на рис. 4.



Рис. 4. Динамика индекса Мосбиржи10 и Портфеля акций

Кроме того, эффективность разработанной системы поддержки инвестиционных решений оценивалась с помощью следующих показателей.

- Средняя годовая доходность инвестиционного портфеля; рассчитывалась по формуле:

$$r_p = \sqrt[n]{\frac{W_n}{W_0}} - 1, \quad (5)$$

где r_p — доходность портфеля; W_n — стоимость портфеля в конце периода; W_0 — стоимость портфеля в начале периода; n — число периодов.

- Риск инвестиционного портфеля, измеренный волатильностью; рассчитывался по формуле:

$$\sigma_p = \sqrt{\frac{\sum_{i=1}^n (r_i - \bar{r})^2}{n}}, \quad (6)$$

где σ_p — риск портфеля; r_i — доходность портфеля в i -том периоде; \bar{r} — средняя доходность портфеля; n — число периодов.

- Коэффициент Шарпа (Sharpe Ratio) — показывает какую доходность получает инвестор на единицу риска [14]. Рассчитывался по формуле:

$$SR = \frac{r_p - r_f}{\sigma_p}, \quad (7)$$

где SR — коэффициент Шарпа; r_p — доходность портфеля; r_f — безрисковая доходность (государственных облигаций); σ_p — риск портфеля.

Показатели эффективности разработанной системы поддержки инвестиционных решений в сравнении с индексной инвестиционной стратегией представлены в таблице 2.

Таблица 2

Метрики качества инвестиционных портфелей

| Инвестиционный портфель | Средняя доходность, % годовых | Риск, % | Коэффициент Шарпа |
|-------------------------|-------------------------------|---------|-------------------|
| Портфель акций | 14.62 | 576.88 | 0.0253 |
| МОЕХ10 | 4.40 | 75.22 | 0.0585 |
| Отклонение | 10.22 | 501.66 | -0.0332 |

Инвестиционный портфель в среднем показал большую доходность 14.62% против 4.40% годовых индексного портфеля МОЕХ10. Одновременно инвестирование в портфель было связано с большим риском — среднегодовая волатильность 576.88% против 75.22% для индексного портфеля МОЕХ10. В результате инвестиционный портфель показал коэффициент Шарпа 0.0253 против 0.0585 для индексного портфеля МОЕХ10. Принимая во внимание, что основной целью инвестора является рост инвестированного капитала, систему принятия инвестиционных решений на основе прогнозов нейронной сети можно признать хорошей.

Заключение. Увеличение количества частных инвесторов на российском финансовом рынке обостряет проблему принятия правильных инвестиционных решений, которые во многом зависят от точного прогнозирования цен на акции. На основе анализа различных методов прогнозирования динамики цен фондовых инструментов выбрана рекуррентная нейронная сеть архитектуры LSTM, с помощью которой построен прогноз значений индекса Московской биржи (MOEX10).

В результате вычислительных экспериментов получена модель, содержащая один слой LSTM с 5 нейронами, оптимизатор Nadam, функция ошибки RMSE. На тестовых данных ошибка прогноза модели с указанными параметрами составила 0.0127.

Для практического использования важно принятие правильного инвестиционного решения, критерием которого является положительный финансовый результат. В результате сравнительного анализа фактической и прогнозной цен генерируется инвестиционная рекомендация. Вычислительные эксперименты показали, что принятие инвестиционных решений, опираясь на прогноз цены, сгенерированной нейронной сетью повышает эффективность инвестирования в индексный портфель Мосбиржи10 по сравнению с эталонной стратегией «купи и держи» за анализируемый период с 45.8% до 229.9%.

Таким образом, построена система поддержки принятия инвестиционных решений на финансовом рынке, использование которой может повысить эффективность портфельного менеджмента.

СПИСОК ЛИТЕРАТУРЫ

1. Число частных инвесторов на Московской бирже достигло 24 млн человек. — Текст : электронный // Московская биржа : официальный сайт. — 2023. — URL: <https://www.moex.com/n54937/?nt=0> (дата обращения : 20.05.2023).
2. Dwivedi S. Analysis and forecasting of Time-Series data using S-ARIMA, CNN and LSTM / S. Dwivedi, A. Attry, D. Parekh, K. Singla. — DOI: 10.1109/ICCCIS51004.2021.9397134. — Text : electronic // 2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS). 19-20 February 2021. India, Greater Noida, 2021. — P. 131-

136. — URL:<https://ieeexplore.ieee.org/document/9397134> (date of the application 20.05.2023).
3. Singh S. Soft computing model coupled with statistical models to estimate future of stock market / S. Singh, K.S. Parmar, J. Kumar. — DOI: 10.1007/s00521-020-05506-1 — Text : electronic // *Neural Comput & Applic.* — 2021. — № 33. — P. 7629-7647. — URL: <https://doi.org/10.1007/s00521-020-05506-1> (date of the application 20.05.2023).
 4. Xiang Y. Using the ARIMA-GARCH model to analyze the fluctuation law of international oil prices. — DOI: 10.1155/2022/3936414 — Text : electronic // *Mathematical Problems in Engineering.* — 2022. № 3936414. P. 1-7. — URL:<https://www.hindawi.com/journals/mpe/2022/3936414/> (date of the application 20.05.2023).
 5. Ince H. Kernel principal component analysis and support vector machines for stock price prediction / H. Ince, T. Trafalis. — DOI: 10.1109/IJCNN.2004.1380933. — Text : electronic // 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541). 25-29 July 2004. Budapest, Hungary, 2004. — P. 2053-2058. — URL:<https://ieeexplore.ieee.org/document/1380933> (date of the application 20.05.2023).
 6. Yin L. Research on stock trend prediction method based on optimized random forest / L. Yin, B. Li, P. Li, R. Zhang. — DOI: 10.1049/cit2.12067. — Text : electronic // *CAAI Trans. Intell. Technol.* — 2021. — № 8. — P. 274-284. — URL: <https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/cit2.12067> (date of the application 20.05.2023).
 7. Sun L. Two-channel attention mechanism fusion model of stock price prediction based on CNN-LSTM / L. Sun, W. Xu, J. Liu. — DOI: 10.2991/978-94-6463-036-7_188. — Text : electronic // *ACM Trans. Asian-Low-Resour. Lang. Inf. Process.* — 2021. — № 20. — P. 1-12. — URL:<https://www.atlantispress.com/proceedings/icedbc-22/125983777> (date of the application 20.05.2023).
 8. Zhang J. Stock Price Prediction Using CNN-BiLSTM-Attention Model / J. Zhang, L. Ye, Y. Lai. — DOI: 10.3390/math11091985. — Text : electronic // *Mathematics.* — 2023. — № 11. — P. 1985. — URL:<https://doi.org/10.3390/math11091985> (date of the application 20.05.2023).
 9. Hochreiter S. Long Short-Term Memory / S. Hochreiter, J. Schmidhuber. — DOI: 10.1162/neco.1997.9.8.1735. — Text : electronic // *Neural Comput.* —

1997. № 9. — P. 1735-1780. — URL:<https://direct.mit.edu/neco/article-abstract/9/8/1735/6109/Long-Short-Term-Memory?redirectedFrom=fulltext> (date of the application 20.05.2023).
10. Wu Q. Ultra-short-term multi-step wind power forecasting based on CNN-LSTM / Q. Wu, F. Guan, C. Lv, Y. Huang. — DOI: 10.1049/rpg2.12085. — Text : electronic // IET Renew. Power Gener. — 2021. — № 15. — P. 1019-1029. — URL:<https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/rpg2.12085> (date of the application 20.05.2023).
11. Sun Y. Prediction of Shanghai stock index based on investor sentiment and CNN-LSTM model / Y. Sun, Q. Sun, S. Zhu. — Direct text // J. Syst. Sci. Inf. Technol. Engl. Ed. — 2022. — № 10. — P. 620-632.
12. Lu W. A CNN-LSTM-based model to forecast stock prices / W. Lu, J. Li, Y. Li, A. Sun, J. Wang. — DOI: 10.1155/2020/6622927. — Text : electronic // Complexity. — 2020. — № 2020. P. 1-10. URL: <https://www.hindawi.com/journals/complexity/2020/6622927/> (date of the application 20.05.2023).
13. Moghar A. Stock market prediction using LSTM recurrent neural network / A. Moghar, M. Hamiche. — DOI: 10.1016/j.procs.2020.03.049. — Text : electronic // Procedia Comput. Sci. — 2020. — № 170. — P. 1168-1173. URL: <https://www.sciencedirect.com/science/article/pii/S1877050920304865?via%3Dihub> (date of the application 20.05.2023).
14. Шарп У. Инвестиции : Учебник / У. Ф. Шарп, Г. Дж. Александер, Дж. В. Бэйли. — Москва : Инфра-М, 2014. — 1028 с. — Текст : непосредственный.