

УДК 004.89

ПРОГНОЗУВАННЯ ФІНАНСОВОГО РИНКУ З ВИКОРИСТАННЯМ НЕЙРОМЕРЕЖЕВОГО ТА ІМУННОГО ПІДХОДІВ

М.М. Корабльов, Д.О. Антонов*Department of Information Systems and Technologies, Kharkiv National University of Radio Electronics, Kharkiv, Ukraine**ORCID <https://orcid.org/0009-0005-2540-7741>**ORCID <https://orcid.org/0009-0000-2079-3413>**E-mail: mykola.korablyov@nure.ua*

АНОТАЦІЯ

Точне прогнозування цін на акції є ключовою задачею підтримки інвестиційних рішень в умовах нестабільних фінансових ринків. Сучасні підходи на основі рекурентних нейронних мереж не повністю використовують довгострокові залежності та міжринкові взаємозв'язки, що погіршує якість прогнозування на волатильних ринках 2022–2025 років [1; 2]. У статті запропоновано гібридну модель прогнозування фінансового ринку, що поєднує три компоненти: трансформер тимчасового злиття (Temporal Fusion Transformer, TFT) для багатовимірного кодування часових рядів акцій з механізмом інтерпретованої уваги; дендритну штучну імунну мережу (daiNet) для автоматичної кластеризації акцій та побудови адаптивного графа взаємозв'язків; графову нейронну мережу (GNN) для спільного навчання на часових та реляційних ознаках. TFT, на відміну від LSTM, забезпечує інтерпретовану увагу до різних часових горизонтів та явне моделювання пікових ринкових подій. Модель верифіковано на щоденних даних 16 технологічних компаній NASDAQ за період з 2022 по 2025 рік, що охоплює різкий спад 2022 року та AI-бум 2023–2024 років. Кластеризація виявила три стійкі ринкові кластери із центрами компаній eBay, Microsoft та Amazon. Якість прогнозу оцінювали за середньоквадратичною похибкою (MSE) на валідаційній і тестовій вибірках: для повної конфігурації (TFT + daiNet + GNN) отримано MSE 1,41 % на тестовому інтервалі. Прогнозовану прибутковість використовували для генерації інвестиційного рішення: для кожного дня тестової вибірки вибирали акцію з максимальною прогнозованою прибутковістю на наступний період. Горизонт прогнозування становив 1–5 днів, а вхідне вікно TFT – 30 торгових днів. Аналіз ваг уваги TFT виявив концентрацію на 5-денному та 20-денному горизонтах, що відповідає тижневим і місячним торговим циклам і має практичну цінність для трейдерів. Відсутність від'ємних кореляцій між усіма 16 компаніями підтверджує загальну синхронізацію ринку в умовах спільних макроекономічних шоків.

Ключові слова: акції, фінансовий ринок, прогнозування, багатовимірні часові ряди, трансформер, дендритна штучна імунна мережа, кластеризація, графова нейронна мережа.

Вступ

Фінансові ринки мають значний вплив на численні сфери людської діяльності: бізнес, освіту, технології та економіку загалом. Прогнозування цін на акції залишається надзвичайно складним завданням через динамічну, нелінійну, нестационарну та хаотичну природу ринку [3–5]. Особливо гостро ця проблема постала у 2022–2025 роках, коли ринки зазнали значних потрясінь: різкого спаду технологічного сектора у 2022 році, банківської кризи у 2023 році та безпрецедентного зростання акцій AI-компаній у 2023–2024 роках. Ціни на акції перебувають під впливом численних взаємопов'язаних факторів – економічних, геополітичних, психологічних та корпоративних, що

ускладнює побудову стабільних прогностичних моделей [6; 7].

Зі стрімким зростанням обсягів фінансових даних традиційні методи аналізу на основі рекурентних нейронних мереж стають дедалі менш ефективними через обмежену здатність до моделювання довгострокових залежностей та відсутність механізмів явного урахування важливості різних часових горизонтів [8]. Між ціновими коливаннями пов'язаних акцій існує кореляційний ефект, а трансформерні архітектури з механізмом уваги здатні ефективніше виявляти ці нелінійні залежності [4; 8–10]. Тож розробка гібридних моделей, що поєднують трансформерне кодування часових рядів із графовим моделюванням взаємозв'язків між акціями, є актуальним завданням

для підвищення якості прогнозування на сучасних волатильних ринках.

Аналіз літературних даних і постановка проблеми

Для інвестування в акції з метою отримання прибутків за мінімальних ризиків застосовують технічний і фундаментальний аналізи [6; 11]. Сучасні досягнення охоплюють чотири категорії методів [4]: статистичні підходи, розпізнавання образів, машинне навчання (МН) та сентимент-аналіз. Серед алгоритмів МН використовувалися дерева рішень, дискримінантний аналіз, наївний класифікатор Байєса, випадковий ліс, логістична регресія та нейронні мережі [8–10]. Домінуючим інструментом стали глибокі нейронні мережі завдяки їх нелінійності та здатності до узагальнення.

Рекурентні нейронні мережі, зокрема LSTM, тривалий час вважалися стандартом для прогнозування часових рядів [12; 13]. Однак останні дослідження показали, що трансформерні архітектури з механізмом уваги можуть мати переваги для фінансових часових рядів: здатність паралельно обробляти послідовність, явно зважувати різні часові горизонти й ефективніше виявляти нелінійні залежності в умовах волатильних ринків [14; 15]. Зокрема, Temporal Fusion Transformer (TFT) [16] поєднує інтерпретовані механізми уваги з гейтуванням для обробки різномірних вхідних ознак.

Водночас більшість існуючих підходів, включно з трансформерними, аналізують акції ізольовано, не враховуючи взаємозв'язків між ними [16]. Систематичний огляд [1] підкреслює, що лише 4,2 % досліджень використовують реляційні дані між акціями. Наразі ці взаємозв'язки переважно визначаються зі статичних галузевих класифікацій, що не відображають реальної динамічної кореляційної структури ринку. Отже, існує потреба в моделі, яка б поєднувала переваги трансформерного кодування часових рядів та адаптивного графового моделювання взаємозв'язків між акціями.

Мета та задачі дослідження

Метою дослідження є розробка гібридної моделі прогнозування фінансового ринку, що поєднує трансформер тимчасового злиття (TFT) для кодування часових рядів акцій із дендритною штучною імунною мережею (daiNet) для кластеризації акцій та графовою нейронною мережею (GNN) для урахування взаємозв'язків між акціями, та її перевірка на даних 2022–2025 років.

Для досягнення мети були поставлені такі задачі:

1) розробити структуру гібридної моделі прогнозування фінансового ринку, що поєднує трансформер TFT, дендритну штучну імунну мережу daiNet та графову нейронну мережу GNN;

2) вибрати метод і виконати кодування часових рядів акцій для виявлення ключових часових горизонтів;

3) вибрати метод і виконати автоматичну кластеризацію акцій для спільного прогнозування;

4) провести експериментальну перевірку запропонованої моделі на даних 16 технологічних компаній NASDAQ за 2022–2025 роки та порівняти з базовими підходами.

Матеріали та методи досліджень

Структура гібридної моделі прогнозування фінансового ринку

Загальну структуру запропонованої гібридної моделі прогнозування фінансового ринку показано на рис. 1. Запропонована гібридна модель поєднує часову та реляційну інформацію. Для кодування часових рядів кожної акції використовується трансформер тимчасового злиття (TFT) [12]. Для визначення взаємозв'язків між акціями у вигляді графа відносин застосовується автоматична кластеризація за допомогою daiNet [17]. Для інтеграції часових ознак, отриманих від TFT, з графом взаємозв'язків, отриманих від daiNet, використовується графова нейронна мережа (GNN) [1].

Вхідними даними TFT є часові ряди торгових характеристик акцій $X_t = \{X_t^1, X_t^2, \dots, X_t^N\}$, $i = 1, \dots, N$, де X_t – вектор ознак акції у торговий день t , T – довжина часового ряду, N – кількість акцій. Для отримання графа взаємозв'язків цінні характеристики акцій p_i подаються на вхід моделі кластеризації, яка реалізована на основі дендритної штучної імунної мережі. Отриманий граф і часові ознаки подаються на вхід GNN, яка прогнозує прибутковість акцій x_t на наступний торговий день.

Результати досліджень

Експериментальні дослідження проводилися з акціями 16 технологічних компаній: Apple (AAPL), Amazon (AMZN), Cisco (CSCO), Electronic Arts (EA), eBay (EBAY), Meta (META), Google (GOOG), IBM (IBM), Intel (INTC), Microsoft (MSFT), Netflix (NFLX), NVIDIA (NVDA), Oracle (ORCL), Qualcomm (QCOM), Tesla (TSLA) та Adobe (ADBE). Запропонована гібридна модель реалізована мовою Python з використанням бібліотеки PyTorch. Денні дані цін акцій за період з 1 січня 2022 року по 1 січня 2025 року отримано через Yahoo Finance API (бібліотека yfinance). Вибраний період охоплює три характерні ринкові фази: різкий спад технологічного сектора (2022), відновлення та банківська криза (2023) та AI-бум (2024).

Для кодування часових рядів акцій використовувався TFT з довжиною вхідного вікна 30 торгових днів (один місяць) та чотирма головами уваги. Задача визначення взаємозв'язків між акціями вирішувалася методом кластеризації daiNet, що дало можливість

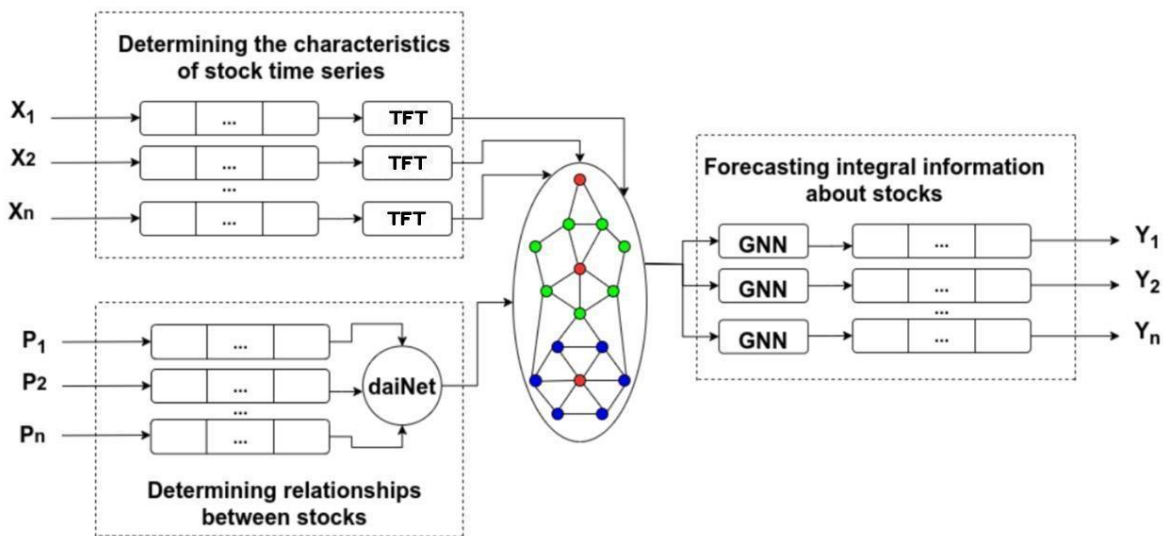


Рис. 1. Структура гібридної моделі прогнозування фінансового ринку

побудувати граф взаємозв'язків (рис. 2). Вершини графа відображають характеристики часових рядів, а ребра – кореляції між акціями.

Кластеризація виявила три стабільні кластери. Кластер 1 (центр – eBay) об'єднує компанії з переважно помірними кореляціями та специфічною динамікою волатильності: eBay, Netflix, NVIDIA, Intel та Oracle. Кластер 2 (центр – Microsoft) включає компанії з найвищими взаємними кореляціями: Microsoft, Cisco, Meta, Adobe та IBM. Кластер 3 (центр – Amazon) охоплює найбільший за складом ринковий

сегмент: Amazon, Google, Apple, Electronic Arts, Tesla та Qualcomm – компанії з вираженою спільною реакцією на макроекономічні тригери 2022–2024 рр.

Отримана теплова карта кореляцій (рис. 3) наочно відображає структуру взаємозв'язків між акціями за період 2022–2025 рр. Характерною особливістю є відсутність від'ємних кореляцій – усі 16 компаній демонструють позитивні взаємозв'язки, що свідчить про загальну синхронізацію ринку в умовах спільних макроекономічних шоків. Найвищі кореляції зафіксовано у парах




Рис. 2. Граф кластеризації технологічних компаній на ринку 2022–2025 рр.




Рис. 3. Теплова карта кореляцій акцій технологічних компаній (2022–2025 рр.)

Microsoft – Google (0,69), Microsoft – Amazon (0,69) та Microsoft – Apple (0,68), що відображає їх спільну реакцію на AI-бум 2023–2024 рр. IBM та Electronic Arts демонструють найнижчі кореляції з іншими компаніями, що підтверджує їх відносну ринкову незалежність.

Експериментальні дані було розбито на три вибірки: навчальна (01.01.2022 – 01.07.2024), валідаційна (01.07.2024 – 01.10.2024) та тестова (01.10.2024 – 01.01.2025). Кількість ітерацій навчання – 500. Як характеристики акцій використовувалися шість типів торгових даних: ціна відкриття, закриття, максимальна та мінімальна ціни, обсяг торгів та швидкість обігу.

Для оцінювання якості прогнозу використано середньоквадратичну похибку MSE (%). Крім оцінки помилки прогнозування, прогнозовану прибутковість використовували для генерації інвестиційного рішення: для кожного дня тестової вибірки вибирали

акцію з найбільшою прогнозою прибутковістю на наступний період.

За результатами експериментів для конфігурації (TFT+daiNet+GNN) на тестовому інтервалі було отримано MSE 1,41 %. Це свідчить про можливість використовувати поєднання темпорального кодування та графового моделювання взаємозв'язків між акціями для зменшення похибки прогнозу.

Обговорення результатів

Отримані результати підтверджують, що поєднання трансформерного кодування часових рядів та імунної кластеризації для визначення взаємозв'язків між акціями з адаптивним графовим моделюванням взаємозв'язків між акціями зменшує похибку прогнозування. Виявлена кластерна структура та теплова карта кореляцій свідчать про наявність стійких груп акцій із синхронною динамікою протягом періоду 2022–2025 рр., а врахування таких зв'язків у графовій

моделі дає можливість підсилити корисний прогностичний сигнал і знизити помилку. Автоматичне формування адаптивного графа через daiNet відображає ринкову структуру, що змінюється із часом, тим самим покращує узгодженість реляційних ознак із фактичною поведінкою ринку.

Для оцінки ефективності запропонованої гібридної моделі доцільно порівняти її з попереднім підходом на основі (LSTM + daiNet + GNN) [17], що використовував рекурентну нейронну мережу замість TFT для кодування часових рядів. У попередній роботі на даних тих самих 16 технологічних компаній за 2021–2023 роки середньоквадратична похибка не перевищувала 2 % для будь-якої акції. Запропонована модель (TFT + daiNet + GNN), верифікована на більш волатильному та протяжному періоді 2022–2025 років, що охоплює три різнохарактерні ринкові фази, досягла MSE 1,41 % на тестовій вибірці. Покращення пояснюється передусім заміною LSTM на TFT: механізм багатоголової уваги дає змогу явно враховувати важливість різних часових горизонтів, що є неможливим у рекурентних архітектурах.

Механізм інтерпретованої уваги TFT дає додаткові переваги перед LSTM: аналіз ваг уваги показав, що модель зосереджується переважно на 5-денних і 20-денних горизонтах, що відповідає тижневим та місячним торговим циклам. Це є практично цінною інформацією для трейдерів та портфельних менеджерів. Виявлення трьох стабільних кластерів із чіткими центрами (eBay, Microsoft, Amazon) протягом усіх трьох ринкових фаз 2022–2025 рр. підтверджує надійність daiNet для виявлення довгострокових ринкових взаємозв'язків. Зокрема, відносна ринкова незалежність IBM та Electronic Arts, що підтверджується як кластерним аналізом, так і тепловою картою (найнижчі кореляції), має практичне значення для диверсифікації інвестиційного портфеля.

Напрямами подальших досліджень є дослідження адаптивного оновлення графа взаємозв'язків у режимі реального часу, інтеграція макроекономічних індикаторів як додаткових ознак TFT, а також розширення набору даних на акції інших секторів та ринків.

Висновки

У статті досліджено сучасні методи прогнозування фінансових ринків та вибрано гібридний підхід, що поєднує трансформерне кодування часових рядів із графовим моделюванням взаємозв'язків між акціями. Наукова новизна роботи:

1) запропоновано гібридну модель прогнозування фінансового ринку, яка, на відміну від існуючих підходів, поєднує трансформер TFT, дендритну штучну імунну мережу daiNet та графову нейронну мережу GNN, що дає можливість одночасно використовувати

переваги механізму інтерпретованої уваги та реляційного моделювання ринку;

2) для кодування часових рядів акцій вибрано метод на основі TFT, що, на відміну від LSTM, явно моделює важливість різних часових горизонтів через механізм багатоголової уваги та забезпечує інтерпретованість прогнозів;

3) для автоматичної кластеризації акцій вибрано метод на основі daiNet та інтеграції реляційного графа через GNN, що, на відміну від статичних галузевих класифікацій, адаптивно відображає реальну кореляційну структуру ринку;

4) проведено експериментальну перевірку на даних 16 технологічних компаній NASDAQ за 2022–2025 роки: для повної конфігурації (TFT + daiNet + GNN) отримано MSE 1,41 % на тестовій вибірці; прогнозовану прибутковість використано для формування рекомендації щодо вибору акції з максимальною прогнозованою прибутковістю на наступний період.

Конфлікт інтересів

Автори декларують, що не мають конфлікту інтересів стосовно цього дослідження, у тому числі фінансового, особистісного характеру, авторства чи іншого характеру, що міг би вплинути на дослідження та його результати, представлені в цій статті.

Фінансування

Дослідження проводилося без фінансової підтримки.

Доступність даних

Дані будуть надані за обґрунтованим запитом.

ЛІТЕРАТУРА

- [1] S. Agrawal, G. Das, A. Garg, "A Systematic Review on Graph Neural Network-based Methods for Stock Market Forecasting," *ACM Computing Surveys*, vol. 57, no. 2, 2024. DOI: 10.1145/3696411.
- [2] T. Phaladisailoed, T. Numnonda, "Stock Price Prediction Using a Hybrid LSTM-GNN Model," *arXiv:2502.15813*, 2025. DOI: 10.48550/arXiv.2502.15813.
- [3] R. Bhowmik, S. Wang, "Stock Market Volatility and Return Analysis: A Systematic Literature Review," *Entropy*, vol. 22, no. 5, p. 522, 2020. DOI: 10.3390/e22050522.
- [4] D. Shah, H. Isah, F. Zulkernine, "Stock Market Analysis: A Review and Taxonomy of Prediction Techniques," *Int. J. Financial Stud.*, vol. 7 (2), 2019, 26. DOI: 10.3390/ijfs7020026.
- [5] C. Krauss, X. A. Do, N. Huck, "Deep Neural Networks, Gradient-Boosted Trees, Random Forests: Statistical Arbitrage on the S&P 500," *European Journal of Operational Research*, vol. 259, no. 2, pp. 689–702, 2017. DOI: 10.1016/j.ejor.2016.10.031.
- [6] H. Liu, S. Huang, P. Wang, Z. Li, "A review of data mining methods in financial markets," *Data Science in Finance*

- and Economics, vol. 1, no. 4, 2021, pp. 362–392. DOI: 10.3934/DSFE.2021020.
- [7] K. Olorunnimbe, H. Viktor, “Deep learning in the stock market – a systematic survey of practice, backtesting, and applications,” *Artificial Intelligence Review*, vol. 56, 2023, pp. 2057–2109. DOI: 10.1007/s10462-022-10226-0.
- [8] M. M. Kumbure, C. Lohrmann, P. Luukka, J. Porras, “Machine learning techniques and data for stock market forecasting: A literature review,” *Expert Systems with Applications*, vol. 197, 2022, 116659. DOI: 10.1016/j.eswa.2022.116659.
- [9] A. Singh, P. Gupta, N. Thakur, “An Empirical Research and Comprehensive Analysis of Stock Market Prediction using Machine Learning and Deep Learning Techniques,” *IOP Conf. Series: MSE*, 1022, 2021, 012098. DOI: 10.1088/1757-899X/1022/1/012098.
- [10] Y. Guo, “Stock Price Prediction Using Machine Learning,” Södertörn University, Master Dissertation, 2022, 41 p.
- [11] Y. J. Chen et al., “A novel technical analysis-based method for stock market forecasting,” *Soft Computing*, vol. 22, 2018, pp. 1295–1312. DOI: 10.1007/s00500-016-2417-2.
- [12] B. Lim, S. Ö. Arik, N. Loeff, T. Pfister, “Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting,” *Int. Journal of Forecasting*, vol. 37 (4), 2021, pp. 1748–1764. DOI: 10.1016/j.ijforecast.2021.03.012.
- [13] A. Vaswani et al., “Attention Is All You Need,” in *Advances in Neural Information Processing Systems 30 (NeurIPS 2017)*, pp. 5998–6008, 2017. DOI: 10.5555/3295222.3295349.
- [14] C. Zhao et al., “Stock Market Analysis Using Time Series Relational Models for Stock Price Prediction,” *Mathematics*, vol. 11 (5), 2023, 1130. DOI: 10.3390/math11051130.
- [15] H. Wang, Y. Zhang, J. Liang, L. Liu, “DAFA-BiLSTM: Deep Autoregression Feature Augmented Bidirectional LSTM network for time series prediction,” *Neural Networks*, vol. 157, 2022, pp. 240–256. DOI: 10.1016/j.neunet.2022.10.009.
- [16] H. Widiputra, A. Mailangkay, E. Gautama, “Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction,” *Complexity*, 2021, 9903518. DOI: 10.1155/2021/9903518.
- [17] M. Korablyov, S. Dykyi, O. Fomichov, I. Ivanisenko, D. Antonov, S. Lutskyi, “Hybrid Stock Analysis Model for Financial Market Forecasting,” in *Proc. IEEE Int. Conf. on Computer Science and Information Technologies (CSIT)*, 2023, pp 1–4. <https://doi.org/10.1109/CSIT61576.2023.10324069>.

FINANCIAL MARKET FORECASTING USING NEURAL NETWORK AND IMMUNE APPROACHES

Mykola Korablyov, Danylo Antonov

Accurate stock price forecasting is a key task for investment decision support in volatile financial markets. Existing recurrent neural network approaches

do not fully capture long-range dependencies and cross-market relationships, which reduces forecast quality on the volatile markets of 2022–2025 [1; 2]. This paper proposes a hybrid financial market forecasting model combining three components: a Temporal Fusion Transformer (TFT) for multivariate time-series encoding with interpretable attention; a Dendritic Artificial Immune Network (daiNet) for automatic stock clustering and adaptive relationship graph construction; and a Graph Neural Network (GNN) for joint learning of temporal and relational features. TFT, unlike LSTM, provides interpretable attention over different time horizons and explicitly models important market events. The model was validated on daily data of 16 NASDAQ technology companies over the 2022–2025 period, covering the 2022 tech crash and the 2023–2024 AI boom. Clustering identified three stable market clusters centered on eBay, Microsoft, and Amazon, reflecting distinct correlation patterns confirmed by heatmap analysis. Forecast quality was evaluated using mean squared error (MSE); the full (TFT + daiNet + GNN) configuration achieved an MSE of 1.41% on the test interval. The predicted returns were also used to generate an investment decision: for each day in the test set, the stock with the highest predicted return for the next period was selected. Experiments were conducted on daily OHLCV data for a set of liquid equities with a 1–5 day forecasting horizon and a 30-day TFT input window. Analysis of TFT attention weights revealed concentration on 5-day and 20-day horizons, corresponding to weekly and monthly trading cycles and providing actionable insights for practitioners. The absence of negative correlations across all 16 companies confirms broad market synchronization under shared macroeconomic shocks.

Keywords: stocks, financial market, forecasting, multidimensional time series, transformer, dendritic artificial immune network, clustering, graph neural network.

REFERENCES

- [1] S. Agrawal, G. Das, A. Garg, “A Systematic Review on Graph Neural Network-based Methods for Stock Market Forecasting,” *ACM Computing Surveys*, vol. 57, no. 2, 2024. DOI: 10.1145/3696411.
- [2] T. Phaladisailoed, T. Numnonda, “Stock Price Prediction Using a Hybrid LSTM-GNN Model,” *arXiv:2502.15813*, 2025. DOI: 10.48550/arXiv.2502.15813.
- [3] R. Bhowmik, S. Wang, “Stock Market Volatility and Return Analysis: A Systematic Literature Review,” *Entropy*, vol. 22, no. 5, p. 522, 2020. DOI: 10.3390/e22050522.
- [4] D. Shah, H. Isah, F. Zulkernine, “Stock Market Analysis: A Review and Taxonomy of Prediction Techniques,” *Int. J. Financial Stud.*, vol. 7 (2), 2019, 26. DOI: 10.3390/ijfs7020026.

- [5] C. Krauss, X. A. Do, N. Huck, “Deep Neural Networks, Gradient-Boosted Trees, Random Forests: Statistical Arbitrage on the S&P 500,” *European Journal of Operational Research*, vol. 259, no. 2, pp. 689–702, 2017. DOI: 10.1016/j.ejor.2016.10.031.
- [6] H. Liu, S. Huang, P. Wang, Z. Li, “A review of data mining methods in financial markets,” *Data Science in Finance and Economics*, vol. 1, no. 4, 2021, pp. 362–392. DOI: 10.3934/DSFE.2021020.
- [7] K. Olorunnimbe, H. Viktor, “Deep learning in the stock market – a systematic survey of practice, backtesting, and applications,” *Artificial Intelligence Review*, vol. 56, 2023, pp. 2057–2109. DOI: 10.1007/s10462-022-10226-0.
- [8] M. M. Kumbure, C. Lohrmann, P. Luukka, J. Porras, “Machine learning techniques and data for stock market forecasting: A literature review,” *Expert Systems with Applications*, vol. 197, 2022, 116659. DOI: 10.1016/j.eswa.2022.116659.
- [9] A. Singh, P. Gupta, N. Thakur, “An Empirical Research and Comprehensive Analysis of Stock Market Prediction using Machine Learning and Deep Learning Techniques,” *IOP Conf. Series: MSE*, 1022, 2021, 012098. DOI: 10.1088/1757-899X/1022/1/012098.
- [10] Y. Guo, “Stock Price Prediction Using Machine Learning,” *Södertörn University, Master Dissertation*, 2022, 41 p.
- [11] Y. J. Chen et al., “A novel technical analysis-based method for stock market forecasting,” *Soft Computing*, vol. 22, 2018, pp. 1295–1312. DOI: 10.1007/s00500-016-2417-2.
- [12] B. Lim, S. Ö. Arık, N. Loeff, T. Pfister, “Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting,” *Int. Journal of Forecasting*, vol. 37 (4), 2021, pp. 1748–1764. DOI: 10.1016/j.ijforecast.2021.03.012.
- [13] A. Vaswani et al., “Attention Is All You Need,” in *Advances in Neural Information Processing Systems 30 (NeurIPS 2017)*, pp. 5998–6008, 2017. DOI: 10.5555/3295222.3295349.
- [14] C. Zhao et al., “Stock Market Analysis Using Time Series Relational Models for Stock Price Prediction,” *Mathematics*, vol. 11 (5), 2023, 1130. DOI: 10.3390/math11051130.
- [15] H. Wang, Y. Zhang, J. Liang, L. Liu, “DAFA-BiLSTM: Deep Autoregression Feature Augmented Bidirectional LSTM network for time series prediction,” *Neural Networks*, vol. 157, 2022, pp. 240–256. DOI: 10.1016/j.neunet.2022.10.009.
- [16] H. Widiputra, A. Mailangkay, E. Gautama, “Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction,” *Complexity*, 2021, 9903518. DOI: 10.1155/2021/9903518.
- [17] M. Korablyov, S. Dykyi, O. Fomichov, I. Ivanisenko, D. Antonov, S. Lutskyy, “Hybrid Stock Analysis Model for Financial Market Forecasting,” in *Proc. IEEE Int. Conf. on Computer Science and Information Technologies (CSIT)*, 2023, pp 1–4. <https://doi.org/10.1109/CSIT61576.2023.10324069>.

Дата першого надходження статті до видання:
14.02.2026

*Дата прийняття статті до друку
після рецензування:* 09.03.2026

Дата публікації (оприлюднення) статті:
12.05.2026



Стаття поширюється
на умовах ліцензії відкритого
доступу CC BY 4.0