

УДК 004.4: 004.94

DOI <https://doi.org/10.32782/tnv-tech.2025.2.14>

АНАЛІЗ ТА АДАПТАЦІЯ ГЕНЕРАТИВНО-ЗМАГАЛЬНИХ МЕРЕЖ ДО ФІНАНСОВИХ РИНКІВ

Перцев Ю. О. – аспірант кафедри інформаційних систем
Навчально-наукового інституту
«Український державний хіміко-технологічний університет»
Українського державного університету науки і технологій
ORCID ID: 0009-0005-6244-3768

Коротка Л. І. – кандидат технічних наук, доцент,
доцент кафедри інформаційних систем Навчально-наукового інституту
«Український державний хіміко-технологічний університет»
Українського державного університету науки і технологій
ORCID ID: 0000-0003-0780-7571

У статті розглянуто можливості застосування генеративно-змагальних мереж (Generative Adversarial Networks, GAN) у завданнях фінансового прогнозування, зокрема для передбачення ціни закриття акцій. Запропоновано нову архітектуру GAN, яка поєднує рекурентну нейронну мережу LSTM у ролі генератора та згорткову нейронну мережу (CNN) у ролі дискримінатора. Метою моделі є генерація синтетичних фінансових рядів, подібних до реальних даних, з подальшим використанням їх для прогнозування цін акцій компанії Apple Inc. У дослідженні використовувалися історичні ринкові дані за п'ятирічний період (2020–2025), що включали понад 30 супутніх ознак, зокрема технічні індикатори, фондові індекси та новинні фактори. Проведено порівняння результатів запропонованої GAN-моделі з класичною LSTM за метрикою середньоквадратичної похибки (RMSE). Отримані результати показали, що генеративна архітектура забезпечує вищу точність прогнозування на тестових вибірках, а також краще моделює нелінійні залежності у фінансових часових рядах.

Дослідження розкриває переваги використання синтетичних даних для навчання моделей, що дозволяє підвищити стабільність і узагальнювальну здатність прогнозів у нестабільному ринковому середовищі. Запропонована модель здатна виявляти як короткострокові, так і довгострокові тренди, що підтверджується числовими експериментами. Архітектура GAN продемонструвала здатність адаптуватися до складних патернів динаміки ринку, що відкриває нові перспективи для побудови інтелектуальних фінансових систем на базі глибокого навчання. Представлені результати можуть бути корисними для трейдерів, фінансових аналітиків, інвесторів, а також дослідників у сфері фінансових технологій, машинного навчання та прикладної економіки.

Ключові слова: генеративно-змагальні мережі, прогнозування фондового ринку, глибоке навчання, LSTM, CNN, синтетичні дані, фінансові часові ряди, машинне навчання, RMSE, технічні індикатори, нейронні мережі, Apple Inc.

Pertsev Yu. O., Korotka L. I. Analysis and adaptation of generative adversarial networks for financial markets

The article investigates the applicability of Generative Adversarial Networks (GAN) for financial forecasting, focusing on the prediction of stock closing prices. A novel GAN architecture is proposed, where the generator is implemented using a Long Short-Term Memory (LSTM) network, and the discriminator is designed as a Convolutional Neural Network (CNN). The primary goal is to synthesize realistic financial time series based on market features, which can be used to train and improve predictive models. The model is trained and tested on a five-year historical dataset (2020–2025) for Apple Inc., incorporating more than 30 input features, including stock price parameters (Open, High, Low, Close, Volume), technical indicators (MACD, EMA, Bollinger Bands), global stock indices, sentiment-related components, and harmonic transformations.

A comparative analysis of the GAN-based model and a classical LSTM model was conducted using Root Mean Square Error (RMSE) as the key performance metric. The results demonstrate that the proposed GAN model achieves superior accuracy and robustness, particularly in identifying nonlinear patterns and complex dependencies within financial time series. Moreover, the use of synthetic data generated by the GAN significantly enhances the training process, leading to better generalization in volatile markets.

The study shows that the GAN architecture is capable of capturing both upward and downward market trends and adjusting to short- and long-term temporal patterns. This adaptability, coupled with the modular design of the network, makes the proposed solution promising for developing AI-powered tools in financial analytics. The research outcomes can be leveraged by traders, investors, financial analysts, and fintech developers aiming to incorporate deep learning-based forecasting methods into practical investment decision-making processes.

Key words: generative adversarial networks, stock market forecasting, deep learning, LSTM, CNN, synthetic data, financial time series, machine learning, RMSE, technical indicators, neural networks, Apple Inc.

Постановка проблеми. Фондовий ринок є складною нелінійною системою, що характеризується високою волатильністю, багатофакторною природою та труднощами в прогнозуванні. Традиційні методи аналізу, такі як статистичні моделі та класичні нейронні мережі, мають обмежену здатність ефективно моделювати складні взаємозв'язки між фінансовими змінними. Одним із перспективних підходів до аналізу фінансових даних є використання генеративно-змагальних мереж (Generative Adversarial Network, GAN). Як відомо, ця архітектура, запропонована Іеном Гудфеллоу в 2014 році, складається з двох нейронних мереж: генератора та дискримінатора, які змагаються між собою, що дозволяє покращувати якість генерованих даних. Застосування GAN на фондовому ринку відкриває можливості для моделювання ринкових тенденцій, синтезу реалістичних фінансових рядів, генерації сценаріїв ризик-менеджменту та навіть тестування алгоритмічних стратегій у середовищах, максимально наближених до реальних ринкових умов.

У роботі пропонується розглянути основні аспекти використання генеративно-змагальних мереж у фінансовому прогнозуванні, провести їх аналіз, дослідити переваги та запропонувати потенційні напрямки подальших досліджень.

Мета роботи. Провести аналіз можливостей та обмежень застосування генеративно-змагальних мереж для прогнозування фондового ринку. Зокрема, зробити огляд теоретичних основ GAN та їх адаптації до фінансового аналізу, розробити підхід для генерації синтетичних фінансових рядів за допомогою GAN та проаналізувати якість отриманих даних. Дослідити вплив синтетичних даних на навчання моделей прогнозування фондового ринку, а також провести порівняння продуктивності GAN-базових методів із традиційними підходами прогнозування. Зробити оцінку переваг, викликів та перспектив застосування генеративно-змагальних мереж у фінансовій сфері. Метою даного дослідження є не лише отримати оцінку потенціалу GAN у фінансовому прогнозуванні, а й визначити практичні рекомендації щодо їх використання для аналітиків, трейдерів та дослідників у сфері фінансових технологій.

Аналіз останніх досліджень і публікацій. Останні дослідження демонструють зростаючий інтерес до застосування генеративно-змагальних мереж у фінансовій сфері, зокрема для прогнозування фондового ринку. Роботи досліджують можливості GAN у моделюванні складних фінансових даних та покращенні точності прогнозів.

Одним із перших підходів до використання GAN у контексті фінансового прогнозування була робота Romero [1], де розглянуто можливість моделювання розподілу цін акцій за допомогою генеративної мережі. Автори Lin et al. [2]

запропонували архітектуру, яка поєднує RNN-генератор та CNN-дискримінатор, що дозволило ефективніше працювати з волатильними ринковими даними. Подальший розвиток цієї ідеї представив Staffini [3], запропонувавши DCGAN, адаптований до фінансових часових рядів, з трансформацією даних у 2D-матриці, які значно покращують розпізнавання патернів. Альтернативне застосування GAN було показано Santoro і Grilli [4], які використовували генеративні мережі для оцінки інформативності новин, не стільки з метою прогнозування, скільки для вимірювання рівня інформаційної насиченості ринку. Емоційний фон фінансових новин все частіше використовується як додаткове джерело ознак у моделюванні. Класичною основою для таких підходів став алгоритм VADER (Hutto & Gilbert) [5], який ефективно застосовується у поєднанні з фінансовими часовими рядами. Foo і Pun [6] об'єднали емоційний тон з інформацією про соціальні взаємодії, використовуючи байєсівський підхід. Cristescu et al. [7] підтвердили ефективність sentiment analysis у прогнозуванні локальних ринків, а Zhang et al. [8] інтегрували аналіз тону у генеративне навчання через механізм Sentiment-Guided Adversarial Learning, де емоційний фон модулює тренування GAN.

Автори Mukherjee et al. [9] представили систематичний огляд застосування глибоких нейронних мереж, серед яких LSTM, GRU, CNN. Водночас, у роботі Naresh et al. [10] показано, що навіть класичні методи, як Random Forest у поєднанні з NLP, можуть бути ефективними для базових задач прогнозування. Робота Malibari et al. [16] акцентує увагу на Transformer-архітектурах, які демонструють високу здатність уловлювати довготривалі залежності у фінансових даних.

Декілька авторів досліджували гібридні архітектури. Підходи до аугментації даних та мульти-масштабного аналізу були розглянуті у працях [17, 18]. Зокрема в роботах [19, 20] продемонстровано, що моделі, які поєднують локальні фільтри CNN із можливістю LSTM моделювати часову динаміку, мають підвищену точність. В роботі [21] адаптували CNN-модель до різних ринків (TAIEX, FTSE), демонструючи хорошу генералізацію. В свою чергу в роботі [22] було показано механізм інтегрування CNN і LSTM з класичними підходами машинного навчання для покращення explainability моделі.

Викладення основного матеріалу. Глибоке навчання останнім часом досягло значних успіхів у багатьох сферах завдяки своїй потужній здатності обробляти дані. Зокрема, широко використовується у фінансовому секторі, у тому числі, для прогнозування фондового ринку, оптимізації портфелів, обробки фінансової інформації та розробки торгових стратегій. Прогнозування фондового ринку є однією з найцінніших і найпопулярніших галузей фінансів [14].

У роботі пропонується нова архітектура генеративно-змагальної мережі, де для прогнозування ціни закриття акцій використовується згортова нейронна мережа (CNN) як дискримінатор і Long Short-Term Memory (LSTM) як генератор. Генератор побудований на основі нейронної мережі LSTM, що приймає на вхід випадковий шум та/або контекстні ознаки (волатильність, індекси настроїв) і генерує синтетичні часові ряди цін акцій, тоді як дискримінатор – це глибока згортова нейронна мережа, яка намагається класифікувати часові ряди як «реальні» (отримані з історичних даних) або «синтетичні» (згенеровані генератором). Архітектура запропонованої моделі представлена на рисунку 1.

Генеративні змагальні мережі поєднують у собі міждисциплінарні концепції, такі як двоосібна гра з нульовою сумою, оптимізаційні підходи навчання нейронних мереж, а також принцип максимізації правдоподібності. У даному контексті генератор позначається як $G(z, P_G)$, де z – це латентний простір, на основі якого



Рис. 1. Архітектура генеративної змагальної мережі

формуються нові дані подібні до реальних, а P_G – параметри (ваги та зміщення), які визначають структуру та поведінку генератора. Метою генератора є створення синтетичних даних, які максимально подібні до реальних.

З іншого боку, дискримінатор позначається як $D(x, P_D)$, де x – зразок даних (реальний або синтетичний), а P_D – параметри нейронної мережі дискримінатора. Завдання дискримінатора – визначити, чи є вхідні дані справжніми (що походять із розподілу реальних даних P_{data}) чи згенерованими (що походять із розподілу P_G).

Формально процес взаємодії між генератором і дискримінатором задається як гра з нульовою сумою з функцією виграшу:

$$\min_G \max_D V(D, G) = E_{x \sim P_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))], \quad (1)$$

де $D(x)$ – це ймовірність, з якою дискримінатор класифікує зразок x як реальний, $G(z)$ – синтетичні дані, створені генератором з випадкового латентного вектора z ,

$D(G(z))$ – оцінка дискримінатора для синтетичних даних (значення в межах $[0, 1]$, де 1 – висока ймовірність реальності) [13].

Метою дискримінатора є максимізація функції виграшу, тобто підвищення достовірності класифікації реальних даних як справжніх (перша частина) і згенерованих як підроблених (друга частина). У той час як генератор прагне мінімізувати цю функцію, змушуючи дискримінатор оцінювати синтетичні зразки як справжні – тобто наближати $D(G(z)) \rightarrow 1$.

Використання натурального логарифму у функції (1) має як статистичне, так і обчислювальне підґрунтя: з точки зору теорії ймовірностей логарифмічна функція є природною в задачах максимізації правдоподібності, а з точки зору оптимізації – її похідні мають зручний вигляд, що спрощує процес оновлення ваг під час зворотного поширення похибки [14].

Розглянемо структуру генератора, який побудований на основі архітектури довгострокової короткочасної пам'яті, що належить до класу рекурентних нейронних мереж (RNN). На відміну від звичайних RNN, LSTM мають вбудовані механізми контролю інформаційного потоку через так звані «затвори» (gates), які дозволяють ефективно зберігати та забувати інформацію в часовому контексті [15].

У запропонованій моделі GAN використовується LSTM як генератор, оскільки ця архітектура добре підходить для обробки послідовностей і зберігає довгострокові залежності в часових рядах, таких як динаміка вартості фінансових активів. У генераторі LSTM-мережа навчається створювати синтетичні часові ряди, що відтворюють статистичні закономірності реальних фінансових даних.

Для навчання використано дані за останні 5 років: з 01.01.2020 по 31.03.2025 рік, що включають 36 ознак, серед яких: цінові параметри (Open, High, Low, Close, Volume), провідні фондові індекси (NASDAQ, S&P 500, FTSE100 тощо), технічні індикатори (MACD, EMA, MA7, MA21, смуги Боллінджера) та гармонічні компоненти. Модель реалізує багатокрокове прогнозування: вхід генератора має тривимірну структуру (batch size, input-step, features), а вихід – (batch size, output-step). Архітектура генератора складається з трьох LSTM-шарів із 1024, 512 та 256 нейронами відповідно, після чого йдуть два щільні (Dense) шари, останній з яких формує прогноз на потрібну кількість кроків уперед. Схема генератора наведена на рисунку 2.




Рис. 2. Структура моделі генератора

У структурі запропонованої GAN-моделі дискримінатор виконує роль класифікатора, завдання якого – відрізнити реальні часові ряди цін акцій від синтетичних, згенерованих LSTM-генератором. Для цього застосовується архітектура згорткової нейронної мережі.

Хоча CNN традиційно застосовуються до задач комп'ютерного зору, в останні роки вони ефективно використовуються й для аналізу одновимірних часових рядів. Завдяки здатності виявляти локальні закономірності у даних, CNN добре підходить для аналізу фінансових сигналів, які можуть містити складні шаблони та структури [13].

Архітектура дискримінатора складається з трьох одновимірних згорткових шарів (1D Convolutional Layers) з 32, 64 та 128 фільтрами відповідно, після яких ідуть три щільні шари (Dense) з 220, 220 та 1 нейроном. У всіх шарах, за винятком вихідного, використовується функція активації Leaky ReLU. Вихідний шар використовує функцію Sigmoid, який забезпечує ймовірнісний вихід у діапазоні [0, 1], що дозволяє моделі визначати справжність даних. Структура моделі дискримінатора наведена на рисунку 3.




Рис. 3. Структура моделі дискримінатора

У дослідженні використано дані про ціни акцій і фондові індекси, отримані з Yahoo Finance за допомогою бібліотеки ufinance, індекс долара – із платформи FRED. Цільовим показником моделі є ціна закриття акцій компанії Apple Inc. Усього набір даних містить 1318 спостережень і 36 змінних. Дані були розділені у співвідношенні 70:30 на тренувальну та тестову вибірки. Статистичні характеристики обчислювались на основі історичних цін закриття. Розраховані технічні індикатори з ціною закриття цінного паперу Apple наведено на рисунку 4.

Як вже зазначалося, метою дослідження є прогнозування ціни закриття акцій, зокрема, на найближчі три дні на основі даних за попередні 30 днів. Для навчання

моделі використовуються не лише історичні ціни закриття, а й 36 додаткових ознак, що потенційно впливають на динаміку ринку. Дані були поділені на тренувальну вибірку (70 %, тобто 923 спостережень) і тестову вибірку (30 %, або 395 спостережень). Після початкового навчання моделі, її продуктивність оцінюється на тестовій вибірці, а отримані результати використовуються для подальшого налаштування моделі.




Рис. 4. Розраховані технічні індикатори з ціною закриття цінного паперу Apple

У запропонованій моделі LSTM на першому шарі використано двонаправлену LSTM (Bidirectional LSTM), що дозволяє моделі враховувати як попередні, так і наступні часові залежності. Для оптимізації навчання застосовано алгоритм Adam з початковою швидкістю навчання 0,001. Розмір пакету (batch) становив 64, а загальна кількість епох – 50.

При тренуванні моделі було використано загальну кількість параметрів 553 349, з яких тренувальних параметрів було 184 449, а параметрів, використаних для навчання 368 900. Результати навчання моделі наведені на рисунку 5.



Рис. 5. Результати навчання моделі LSTM

Після поділу на тренувальну й тестову вибірки, тестовий період починається з 12 вересня 2023 року. Результати тестування наведені на рисунку 6.

В таблиці 1 наведені реальні та прогнозовані ціни закриття використовуючи модель LSTM.

У дослідженні реалізовано архітектуру генеративно-змагальної мережі, в якій функції втрат розраховуються як для генератора, так і для дискримінатора з метою



Рис. 6. Результати тестування моделі LSTM

Таблиця 1

Порівняння реальної ціни закриття цінного паперу та прогнозованої за допомогою LSTM

Дата	Реальна ціна	Прогнозована ціна
25.03.2025	223,75	217,83
26.03.2025	221,52	219,32
27.03.2025	223,85	219,44
28.03.2025	217,89	219,28
31.03.2025	222,13	217,64

оптимізації їхньої взаємодії. Функція втрат GAN виступає як цільова функція, що визначає напрям навчання та оцінює ступінь розбіжності між результатами генератора та оцінками дискримінатора.

Для генератора ця втрата стимулює створення таких синтетичних зразків, які важко відрізнити від справжніх даних. Генератор навчається так, щоб мінімізувати свою функцію втрат, що дозволяє йому дедалі ефективніше «обманювати» дискримінатор. Формально функція втрат генератора може бути представлена у вигляді:

$$L_G = -\sum_{i=0}^m (\log D(y_i)) + \log(1 - D(G(x_i))). \quad (2)$$

Для дискримінатора функція втрат відображає його здатність точно розрізнити справжні та згенеровані дані. Його мета – мінімізувати цю втрату шляхом покращення своїх дискримінативних властивостей. Формула функції втрат для дискримінатора має вигляд:

$$L_D = -\frac{1}{m} \sum_{i=0}^m \log D(G(x_i)). \quad (3)$$

Таким чином, у змагальному навчанні обидва компоненти – генератор і дискримінатор – взаємно вдосконалюються: генератор прагне створити правдоподібні зразки, тоді як дискримінатор вчиться їх точно ідентифікувати.

На рисунку 7 зображено графік втрат (loss plot) моделі GAN: синя лінія відображає втрати дискримінатора, а помаранчева – генератора.




Рис. 7. Графік втрат моделі GAN

Для навчання GAN моделі було застосовано оптимізатор Adam з коефіцієнтом навчання 0,00016, розмір пакету (batch) становить 128, а загальна кількість епох – 165. Як вхід до моделі GAN, використано повний набір даних, що охоплює 5 років історичних значень фондового ринку та 36 супровідних ознак. При тренуванні моделі було використано загальну кількість параметрів 128 301, з яких тренувальних параметрів було 128 301. Результати навчання моделі наведені на рисунку 8.



Рис. 8. Результати навчання моделі GAN

На рисунку 8 продемонстровано результати навчання GAN-моделі. Аналіз графіка дозволяє зробити висновки, що на початку прогнозовані ціни починають суттєво відхилятися від реальних через те, що недостатня кількість параметрів для точного прогнозування, але вже з середини значення прогнозованої ціни стає більш точним через те, що модель вже більш адекватно оцінює отриманні значення.

Данні для тестування складають 30 % від загального діапазону і після поділу на тренувальні і навчальні починаються з 12 вересня 2023 року. Результати тестування для моделі GAN наведені на рисунку 9.

В таблиці 2 наведені ціни закриття реальні та прогнозовані із використанням моделі GAN.

Для оцінки точності кожної з побудованих моделей використовувався показник середньоквадратичної похибки (RMSE, *Root Mean Square Error*), що є загальноживим критерієм якості прогнозування:



Рис. 9. Результати тестування моделі GAN

Таблиця 2

**Порівняння цін закриття реальних та прогнозованих
із використанням GAN**

Дата	Реальна ціна	Прогнозована ціна
25.03.2025	223,75	219,34
26.03.2025	221,52	221,11
27.03.2025	223,85	222,55
28.03.2025	217,89	222,78
31.03.2025	222,13	221,57

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (4)$$

де y_i – фактичне значення ціни акції в момент часу i ,

$\hat{y}_i$ – відповідне прогнозоване значення,

n – загальна кількість спостережень.

Процедура обчислення виконується для кожної точки з доступного набору даних, у результаті чого отримується одне числове значення, що відображає загальну похибку прогнозування. RMSE акцентує увагу на більших похибках, оскільки зводить до квадрата різницю між фактичним та прогнозованим значенням, тим самим накладаючи сильніші штрафування на великі відхилення. Таким чином, цей показник є комплексною мірою точності, яка враховує як величину, так і напрям похибки [14].

Менше значення RMSE свідчить про вищу точність моделі, оскільки означає менші середні відхилення між передбаченими та фактичними значеннями. Навпаки, більше значення RMSE вказує на нижчу якість прогнозування.

Для оцінювання ефективності моделі передбачення цін акцій обчислювались значення RMSE окремо для тренувальної та тестової вибірок. Крім того, було застосовано стандартизований показник RMSE, який розраховується як відношення:

$$Standardized\ RMSE = \frac{RMSE(y_{true}, y_{pred})}{RMSE(y_{true}[1:], y_{true}[:-1])}, \quad (5)$$

де y_{true} – справжні значення цін акцій,

y_{pred} – передбачені значення,

$y_{true}[1:]$, $y_{true}[:-1]$ зсунутий набір фактичних даних для порівняння з лаговими значеннями.

У таблиці 3 наведено порівняння точності розробленої моделі з базовою моделлю LSTM.

Таблиця 3

Порівняння точності моделей

Модель	RMSE (Навчальний)	RMSE (Тренування)	Стандартизований RMSE (Тренування)
LSTM	7,982	8,428	1,405
GAN-LSTM	4,296	7,883	1,314

Висновки. У дослідженні було запропоновано модель, що базується на генеративній змагальній мережі, де генератор побудований на основі LSTM, а дискримінатор реалізовано у вигляді згорткової нейромережі. На основі проведених чисельних експериментів та отриманих результатів можна зробити кілька важливих висновків.

По-перше, запропонована модель продемонструвала конкурентоспроможну якість прогнозування у порівнянні з попередніми дослідженнями, де застосовувались методи машинного навчання із застосуванням нейромережових моделей [11]. Якість їх навчання здійснювалося за метрикою середньоквадратичної похибки (RMSE), що є одним із ключових показників точності прогнозу.

По-друге, модель виявила здатність адекватно розпізнавати як висхідні, так і низхідні тренди на фондовому ринку, що надає корисну аналітичну інформацію для формування інвестиційних рішень.

Водночас варто зазначити, що в окремих випадках, наприклад, для акцій Apple Inc., які продемонстрували стрімке зростання у 2023 році, модель не змогла повною мірою відтворити темпи цього зростання, що може свідчити про необхідність подальшого удосконалення підходів для більш точного відтворення таких нетипових коливань.

У майбутніх дослідженнях доцільно приділити особливу увагу оптимізації гіперпараметрів моделі. Водночас варто пам'ятати, що результати прогнозу не повинні розглядатися як єдина основа для прийняття інвестиційних рішень, а лише як один з інструментів підтримки аналітичного процесу.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ:

1. Alberto, R., & Romero, C. (2019). Generative Adversarial Network for Stock Market price Prediction. URL: https://cs230.stanford.edu/projects_fall_2019/reports/26259829.pdf
2. Lin, H., Chen, C., Huang, G. & Jafari, A. (2021). Stock price prediction using Generative Adversarial Networks. Journal of Computer Science, 17(3), 188–196. DOI: <https://doi.org/10.3844/jcssp.2021.188.196>
3. Staffini A (2022) Stock Price Forecasting by a Deep Convolutional Generative Adversarial Network. Front. Artif. Intell. 5:837596. DOI: <https://doi.org/10.3389/frai.2022.837596>
4. Santoro, D., Grilli, L. (2022) Generative adversarial network to evaluate quantity of information in financial markets. Neural Comput. Appl. 34, 17473–17490. DOI: <https://doi.org/10.1007/s00521-022-07401-3>

5. Hutto, C., & Gilbert, E. (2014). VADER: A Parsimonious Rule-Based Model for Sentiment Analysis of Social Media Text. *Proceedings of the International AAAI Conference on Web and Social Media*, 8(1), 216–225. DOI: <https://doi.org/10.1609/icwsm.v8i1.14550>
6. M. J. R. Foo and C. S. Pun, (2022) “Stock Movement Prediction with Social Sentiments and Interactional Data: Integrating NLP and Bayesian Frameworks”, 2022 4th International Conference on Natural Language Processing (ICNLP), Xi'an, China, 2022, pp. 530–536, DOI: <https://doi.org/10.1109/ICNLP55136.2022.00097>.
7. Cristescu, M. P., Nerisanu, R. A., Mara, D. A., & Oprea, S.-V. (2022). Using Market News Sentiment Analysis for Stock Market Prediction. *Mathematics*, 10(22), 4255. DOI: <https://doi.org/10.3390/math10224255>
8. Zhang Y, Li J, Wang H and Choi S-CT (2021) Sentiment-Guided Adversarial Learning for Stock Price Prediction. *Front. Appl. Math. Stat.* 7:601105. DOI: <https://doi.org/10.3389/fams.2021.601105>
9. S. Mukherjee, B. Sadhukhan, N. Sarkar, D. Roy, and S. De, (2023) “Stock market prediction using deep learning algorithms,” *CAAI Transactions on Intelligence Technology*, vol. 8, no. 1, pp. 82–94 DOI: <https://doi.org/10.1049/cit2.12059>
10. E. Naresh, B. J. Ananda, K. S. Keerthi and M. R. Tejonidhi, (2022) “Predicting the Stock Price Using Natural Language Processing and Random Forest Regressor”, 2022 IEEE International Conference on Data Science and Information System (ICDSIS), Hassan, India, 2022, pp. 1-5, DOI: <https://doi.org/10.1109/ICDSIS55133.2022.9915940>
11. Перцев Ю. О., Коротка Л. І. (2025) Порівняльний аналіз традиційних статистичних методів та нейромережевої моделі LSTM. *Системні технології*. № 1(156). С. 65–77.
12. Перцев Ю. О., Коротка Л. І. (2024) Інноваційний підхід у прогнозуванні часових рядів: від традиційних методів до новаторської моделі TIMESFM. *International scientific and technical conference Information Technologies in Metallurgy and Machine building (Україна, м. Дніпро, 10-11 квітня 2024 року)*, Дніпро: ITMM 2024, С. 434–439.
13. Korotka L., Klevzhyts D., Shvydko D. (2024) Use of generative-adversarial networks when creating content. Artificial intelligence. *National Academy of Sciences of Ukraine Institute of Artificial Intelligence Problems MES of Ukraine and NAS of Ukraine*. 2024 № 2 (99). P. 32–47.
14. Перцев Ю. О., Коротка Л. І. (2023) Нейромережеве прогнозування цін на фондовому ринку. *International scientific and technical conference Information Technologies in Metallurgy and Machine building (Україна, м. Дніпро, 22 березня 2023 року)*, Дніпро : ITMM 2023, С. 314–317.
15. Перцев Ю. О., Коротка Л. І. (2023) Порівняння нейронних мереж RNN та LSTM типу при прогнозуванні цін на фондовому ринку. *Матеріали VIII Міжнародної науково-технічної конференції комп'ютерне моделювання та оптимізація складних систем (Україна, м. Дніпро, 1–3 листопада 2023 року)*. Дніпро : КМОСС-2023 С. 124–127.
16. Nadeem Malibari, Iyad Katib and Rashid Mehmood, (2021) “Predicting Stock Closing Prices in Emerging Markets with Transformer Neural Networks: The Saudi Stock Exchange Case” *International Journal of Advanced Computer Science and Applications(IJACSA)*, vol. 12, no. 12. DOI: <http://dx.doi.org/10.14569/IJACSA.2021.01212106>
17. Guennec, A. L., Malinowski, S. & Tavenard, R. (2016). Data Augmentation for Time Series Classification using Convolutional Neural Networks URL: <https://halshs.archives-ouvertes.fr/halshs-01357973/>
18. Cui, Zhicheng & Chen, Wenlin. (2016). Multi-Scale Convolutional Neural Networks for Time Series Classification. DOI: <https://doi.org/10.48550/arXiv.1603.06995>.
19. Kim T, Kim HY (2019) Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data. *PLoS ONE* 14(2): e0212320. DOI: <https://doi.org/10.1371/journal.pone.0212320>

20. Lu, Wenjie & Li, Jiazheng & Li, Yifan & Sun, Aijun & Wang, Jingyang. (2020). A CNN-LSTM-based model to forecast stock prices. *Complexity*. 2020. 1–10. DOI: <https://doi.org/10.1155/2020/6622927>

21. Kirisci, Melih & Cagcag Yolcu, Ozge. (2022). A New CNN-Based Model for Financial Time Series: TAIEEX and FTSE Stocks Forecasting. *Neural Processing Letters*. 54. 10.1007/s11063-022-10767-z.

22. Mehtab, S., Sen, J. (2022). Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models. In: Sahoo, J. P., Tripathy, A. K., Mohanty, M., Li, K.C., Nayak, A. K. (eds) *Advances in Distributed Computing and Machine Learning. Lecture Notes in Networks and Systems*, vol. 302. Springer, Singapore. DOI: https://doi.org/10.1007/978-981-16-4807-6_39

REFERENCES:

1. Alberto, R., & Romero, C. (2019). Generative Adversarial Network for Stock Market price Prediction. URL: https://cs230.stanford.edu/projects_fall_2019/reports/26259829.pdf

2. Lin, H., Chen, C., Huang, G. & Jafari, A. (2021). Stock price prediction using Generative Adversarial Networks. *Journal of Computer Science*, 17(3), 188–196. DOI: <https://doi.org/10.3844/jcssp.2021.188.196>

3. Staffini A (2022) Stock Price Forecasting by a Deep Convolutional Generative Adversarial Network. *Front. Artif. Intell.* 5:837596. DOI: <https://doi.org/10.3389/frai.2022.837596>

4. Santoro, D., Grilli, L. (2022) Generative adversarial network to evaluate quantity of information in financial markets. *Neural Comput. Appl.* 34, 17473–17490. DOI: <https://doi.org/10.1007/s00521-022-07401-3>

5. Hutto, C., & Gilbert, E. (2014). VADER: A Parsimonious Rule-Based Model for Sentiment Analysis of Social Media Text. *Proceedings of the International AAAI Conference on Web and Social Media*, 8(1), 216–225. DOI: <https://doi.org/10.1609/icwsm.v8i1.14550>

6. M. J. R. Foo and C. S. Pun, (2022) “Stock Movement Prediction with Social Sentiments and Interactional Data: Integrating NLP and Bayesian Frameworks”, 2022 4th International Conference on Natural Language Processing (ICNLP), Xi'an, China, 2022, pp. 530–536, DOI: <https://doi.org/10.1109/ICNLP55136.2022.00097>

7. Cristescu, M. P., Nerisanu, R. A., Mara, D. A., & Oprea, S.-V. (2022). Using Market News Sentiment Analysis for Stock Market Prediction. *Mathematics*, 10(22), 4255. DOI: <https://doi.org/10.3390/math10224255>

8. Zhang Y, Li J, Wang H and Choi S-CT (2021) Sentiment-Guided Adversarial Learning for Stock Price Prediction. *Front. Appl. Math. Stat.* 7:601105. DOI: <https://doi.org/10.3389/fams.2021.601105>

9. S. Mukherjee, B. Sadhukhan, N. Sarkar, D. Roy, and S. De, (2023) “Stock market prediction using deep learning algorithms”, *CAAI Transactions on Intelligence Technology*, vol. 8, no. 1, pp. 82–94 DOI: <https://doi.org/10.1049/cit2.12059>

10. E. Naresh, B. J. Ananda, K. S. Keerthi and M. R. Tejonidhi, (2022) “Predicting the Stock Price Using Natural Language Processing and Random Forest Regressor”, 2022 IEEE International Conference on Data Science and Information System (ICDSIS), Hassan, India, 2022, pp. 1–5, DOI: <https://doi.org/10.1109/ICDSIS55133.2022.9915940>

11. Pertsev Y. O., Korotka L. I. (2025) Porivnialnyi analiz tradytsiynykh statystychnykh metodiv ta neiromerezhevoi modeli LSTM [Comparative analysis of traditional statistical methods and the LSTM neural network model]. *System technologies*, vol. 1, no. 156, pp. 65–77. DOI: <https://doi.org/10.34185/1562-9945-1-156-2025-08>

12. Pertsev Y. O., Korotka L. I. (2024) Innovatsiyni pidkhid u prohnozuvanni chasovykh riadiv: vid tradytsiynykh metodiv do novatorskoi modeli TIMESFM.

[An Innovative Approach to Time Series Forecasting: From Traditional Methods to the groundbreaking TIMESFM Model]. Proceedings of the *International scientific and technical conference Information Technologies in Metallurgy and Machine building (Ukraine, Dnipro, April 10-11, 2024)*, Dnipro: ITMM 2024. pp. 434–439. DOI: <https://doi.org/10.34185/1991-7848.itmm.2024.01.084>

13. Korotka L., Klevzhyts D., Shvydko D. (2024) Use of generative-adversarial networks when creating content. Artificial intelligence. [Use of generative-adversarial networks when creating content. Artificial intelligence.] *National Academy of Sciences of Ukraine Institute of Artificial Intelligence Problems MES of Ukraine and NAS of Ukraine*, vol. 2, no. 99, pp. 32–47.

14. Pertsev Y. O., Korotka L. I. (2023) Neiromerezheve prohozuvannia tsin na fondovomu rynku [Neural Network-Based Stock Market Price Forecasting]. Proceedings of the *International scientific and technical conference Information Technologies in Metallurgy and Machine building (Ukraine, Dnipro, March 22, 2023)*, Dnipro : ITMM 2023, pp. 314–317. DOI: <https://doi.org/10.34185/1991-7848.itmm.2023.01.085>

15. Pertsev Y. O., Korotka L. I. (2023) Porivniannia neironnykh merezh RNN ta LSTM typu pry prohozuvanni tsin na fondovomu rynku [Comparison of RNN and LSTM Neural Networks in Stock Market Price Prediction]. Proceedings of the *Materialy VIII Mizhnarodnoi naukovo-tekhnichnoi konferentsii kompiuterne modeliuivannia ta optymizatsiia skladnykh system (Ukraine, Dnipro, November 1-3, 2023)*, Dnipro : CMOCS-2023, pp. 124–127.

16. Nadeem Malibari, Iyad Katib and Rashid Mehmood, (2021) “Predicting Stock Closing Prices in Emerging Markets with Transformer Neural Networks: The Saudi Stock Exchange Case” *International Journal of Advanced Computer Science and Applications(IJACSA)*, vol. 12, no. 12. DOI: <http://dx.doi.org/10.14569/IJACSA.2021.01212106>

17. Guennec, A. L., Malinowski, S. & Tavenard, R. (2016). Data Augmentation for Time Series Classification using Convolutional Neural Networks URL: <https://halshs.archives-ouvertes.fr/halshs-01357973/>

18. Cui, Zhicheng & Chen, Wenlin. (2016). Multi-Scale Convolutional Neural Networks for Time Series Classification. DOI: <https://doi.org/10.48550/arXiv.1603.06995>.

19. Kim T, Kim HY (2019) Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data. *PLoS ONE* 14(2): e0212320. DOI: <https://doi.org/10.1371/journal.pone.0212320>

20. Lu, Wenjie & Li, Jiazheng & Li, Yifan & Sun, Aijun & Wang, Jingyang. (2020). A CNN-LSTM-based model to forecast stock prices. *Complexity*. 2020. 1–10. DOI: <https://doi.org/10.1155/2020/6622927>

21. Kirisci, Melih & cagcag yolcu, Ozge. (2022). A New CNN-Based Model for Financial Time Series: TAIEX and FTSE Stocks Forecasting. *Neural Processing Letters*. 54. 10.1007/s11063-022-10767-z

22. Mehtab, S., Sen, J. (2022). Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models. In: Sahoo, J. P., Tripathy, A. K., Mohanty, M., Li, KC., Nayak, A.K. (eds) *Advances in Distributed Computing and Machine Learning. Lecture Notes in Networks and Systems*, vol 302. Springer, Singapore. DOI: https://doi.org/10.1007/978-981-16-4807-6_39