

УДК 519.6 + 336.74

JEL Classification: C45, C53, G11

DOI: 10.20535/2307-5651.32.2025.328561

Клебан Ю. В.старший викладач кафедри інформаційних технологій та аналітики даних
(відповідальний автор)

ORCID ID: 0000-0002-7070-5175

Національний університет «Острозька Академія»

Коношук Є. А.

студент

ORCID ID: 0009-0008-3088-2661

Національний університет «Острозька Академія»

Kleban Yuriy, Konoshchuk Yevhen

National University of Ostroh Academy

ПОРІВНЯЛЬНИЙ АНАЛІЗ ЕФЕКТИВНОСТІ НЕЙРОННИХ МЕРЕЖ ТА АНСАМБЛЕВИХ МЕТОДІВ У ПРОГНОЗУВАННІ ЦІН КРИПТОВАЛЮТ

COMPARATIVE ANALYSIS OF THE EFFECTIVENESS OF NEURAL NETWORKS AND ENSEMBLE METHODS IN CRYPTOCURRENCY PRICE PREDICTION

У статті проведено порівняльний аналіз ефективності різних методів машинного навчання для прогнозування цін криптовалют. Дослідження охоплює шість популярних криптовалют: Bitcoin, Ethereum, Binance Coin, Cardano, Ripple та Litecoin. Для прогнозування використано рекурентні нейронні мережі (RNN, LSTM) та ансамблеві методи (XGBoost, Random Forest). Дані були зібрані за період з 1 січня 2021 року по 17 лютого 2025 року, а для оцінки точності моделей застосовано метрики RMSE, MAE та MAPE. Результати показали, що LSTM демонструє найкращу точність для Bitcoin та Binance Coin, тоді як ансамблеві методи (XGBoost та Random Forest) виявилися ефективнішими для Ethereum та Litecoin. Для Cardano та Ripple найкращі результати показала модель RNN. Дослідження підтвердило, що вибір моделі для прогнозування цін криптовалют має враховувати специфіку кожного активу, зокрема його волатильність та історичну динаміку. Стаття пропонує рекомендації щодо вибору оптимальних методів для прогнозування цін криптовалют, що може бути корисним для інвесторів та учасників ринку цифрових активів.

Ключові слова: криптовалюти, прогнозування цін, машинне навчання, нейронні мережі, ансамблеві методи, LSTM, RNN, XGBoost, Random Forest.

Cryptocurrency price prediction is important for financial analysis and decision-making in the digital asset market. Cryptocurrencies are characterised by high volatility and complex dynamics, which complicates traditional forecasting methods. This study compared the effectiveness of four machine learning models for predicting the prices of six cryptocurrencies: Bitcoin, Ethereum, Binance Coin, Cardano, Ripple, and Litecoin. Recurrent Neural Networks (RNN, LSTM) and ensemble methods such as XGBoost and Random Forest were used, allowing for the assessment of their ability to predict prices based on historical data accurately. The data used for modelling was collected from January 1, 2021, to February 17, 2025, and included information on closing prices, trading volumes, and other cryptocurrency characteristics. Data normalization was applied using the min-max method to ensure the proper functioning of the models. Each cryptocurrency was predicted separately, and training and testing datasets were created to evaluate the accuracy of each model. The models were evaluated using three main metrics: RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), and MAPE (Mean Absolute Percentage Error). The results showed that all models demonstrated good prediction accuracy, but with varying levels of performance for different cryptocurrencies. For instance, LSTM models proved to be the best for Bitcoin and Binance Coin, while RNN models achieved the lowest error for Cardano and Ripple. On the other hand, for Ethereum and Litecoin, ensemble models like XGBoost and Random Forest provided the best results. The results of the study confirm the high effectiveness of both neural networks and ensemble methods for predicting cryptocurrency prices. However, further improvements in models and the combination of multiple methods could lead to even more accurate results. An additional promising direction for future research is the incorporation of other factors, such as social sentiment or news, to enhance the accuracy of predictions. These additional features could provide a more comprehensive understanding of market trends and improve forecasting performance in real-world scenarios.

Keywords: cryptocurrencies, price prediction, machine learning, neural networks, ensemble methods, LSTM, RNN, XGBoost, Random Forest.

Постановка проблеми. Ринок криптовалют характеризується високою волатильністю та непередбачуваністю, що робить прогнозування цін складним завданням. Висока мінливість цін обумовлена різноманітними факторами, такими як ринкові настрої, регуляторні зміни та загальний інтерес до цифрових активів [1]. Точне прогнозування цін криптовалют має вирішальне значення для інвесторів, трейдерів та

розробників політики, оскільки воно може допомогти приймати обґрунтовані рішення та управляти ризиками [2]. Крім того, точні прогнози можуть сприяти покращенню ліквідності ринку та зниженню втрат, пов'язаних з помилковими стратегіями.

Традиційні статистичні методи часто не здатні зафіксувати складні нелінійні закономірності в даних про ціни криптовалют. Наприклад, такі методи, як

ARIMA, демонструють обмежену ефективність через високу волатильність і динамічну природу ринків криптовалют [3]. Тому, методи глибокого навчання та ансамблеві методи набули значної популярності для прогнозування цін криптовалют завдяки їхній здатності обробляти великі обсяги даних і виявляти складні взаємозв'язки. Ці методи мають високу здатність до моделювання нелінійних патернів та дозволяють враховувати широкий спектр вхідних змінних [4].

Крім того, важливо дослідити, як моделі можуть адаптуватися до різких змін на ринку криптовалют, таких як ті, що викликані непередбачуваними подіями або змінами в ринкових настроях. Така адаптація є критичною для розробки моделей, здатних зберігати точність у періоди аномальних ринкових коливань.

Аналіз останніх досліджень і публікацій. Огляд літератури показує, що для прогнозування цін на криптовалюті використовують широкий спектр методів, починаючи від традиційних статистичних моделей і закінчуючи складними алгоритмами машинного та глибокого навчання. Чуантай Дж. та Йонг Лі дослідили, що традиційні методи, такі як проста експоненційна згладжувальна (SES) та ARIMA, часто застосовуються для прогнозування часових рядів, але вони мають обмеження у точності через високу волатильність криптовалют [1]. Ці моделі нееластичні щодо нестационарності ринкових даних і мають складнощі з прогнозуванням цін на тривалих часових горизонтах.

У дослідженні Бутеска А. та інших Random Forest та інші ансамблеві методи продемонстрували значне покращення точності у прогнозуванні завдяки здатності виявляти складні нелінійні зв'язки у даних [4]. Ці моделі дозволяють краще враховувати мінливість ринку та адаптуватися до змінних умов.

Клебан Ю. та Стасюк Т. також розглядають можливість використання нейронних мереж для прогнозування цін на криптовалюті [5]. Автори акцентують увагу на високій волатильності та складних ринкових динаміках криптовалют, таких як Bitcoin, Ethereum та Ripple, що робить традиційні методи прогнозування менш ефективними.

Особлива увага у дослідженнях приділяється моделям глибокого навчання, а саме LSTM (Long Short-Term Memory) та RNN (Recurrent Neural Networks), які ефективно працюють із часовими рядами завдяки здатності враховувати довготривалі залежності в даних [4]. LSTM вирізняється своєю здатністю розв'язувати проблему зникаючого градієнту, характерну для стандартних RNN, що забезпечує більш точне прогнозування на основі історичних даних. Окрім цього, Нандан С. та Уша С.Р. у своєму дослідженні зазначають використання GRU (Gated Recurrent Unit) як альтернативи з простішою структурою, але зі схожою ефективністю [6], а Ен В. та Лью Л. пропонують інтеграцію CNN (Convolutional Neural Networks) для вилучення ознак із даних, що можуть бути використані у моделях прогнозування [7]. Результати більшості досліджень свідчать, що моделі глибокого навчання перевершують традиційні підходи в точності прогнозування цін на криптовалюті, такі як Bitcoin та Ethereum.

Омоле О. та Енке Д. у 2024 році дослідили вплив різноманітних факторів на ціни криптовалют, зокрема роль ончейн-даних, які використовуються для прогнозування вартості Bitcoin [8]. Аналіз даних із соціальних

мереж, таких як Reddit і Twitter, дозволяє виявити важливі тренди, що впливають на ринкові коливання.

Сіддхарт Д. та Каушик Дж. зазначають, що існуючі дослідження зазвичай зосереджуються на прогнозуванні цін лише на найбільш популярних криптовалютах, таких як Bitcoin і Ethereum [9]. Водночас менш відомі криптовалюти можуть демонструвати значні відмінності в цінній динаміці та волатильності, що потребує окремого підходу до їх аналізу.

Формулювання цілей статті. Метою статті є проведення порівняльного аналізу ефективності нейронних мереж (LSTM, RNN) та ансамблевих моделей (XGBoost, Random Forest) для прогнозування цін криптовалют. Дослідження орієнтоване на оцінку точності кожної моделі з використанням ключових метрик, таких як RMSE, MAE та MAPE, що дозволить визначити найбільш ефективні підходи для різних типів криптовалют із варіативною ціновою динамікою. Крім того, дослідження має на меті визначити здатність моделей адаптуватися до різких ринкових коливань, викликаних непередбачуваними подіями або змінами в настроях учасників ринку. Результати дозволять визначити, яка модель є найбільш підходящою для прогнозування цін криптовалют з різними характеристиками та які підходи можуть бути застосовані для підвищення точності прогнозів в умовах високої волатильності. Це дасть змогу розробити більш ефективні торгові стратегії та знизити ризики, пов'язані з непередбачуваністю ринку криптовалют.

Виклад основного матеріалу. Для моделювання було зібрано щоденні дані про шість криптовалют – Bitcoin, Ethereum, Binance Coin, Cardano, Ripple та Litecoin – за період з 1 січня 2021 року по 17 лютого 2025 року з платформи CoinMarketCap. Вибір цих криптовалют пояснюється їхньою роллю та значенням на ринку. Bitcoin та Ethereum були обрані як дві найбільші та найвпливовіші криптовалюти: Bitcoin є першою та найпопулярнішою цифровою валютою, що виконує функцію «цифрового золота», тоді як Ethereum забезпечує платформу для смарт-контрактів і децентралізованих додатків. Binance Coin та Cardano представляють популярні альткоїни: Binance Coin використовується в екосистемі Binance для зниження комісій, а Cardano вирізняється науковим підходом до розробки та високою масштабованістю. Ripple та Litecoin були включені через їхню високу ліквідність і використання у фінансових операціях: Ripple орієнтований на міжнародні платежі та банківські перекази, а Litecoin є швидшою та дешевшою альтернативою Bitcoin для щоденних транзакцій.

Зібраний набір даних містить основні показники: дату (Date), ціну закриття (Close), ціну відкриття (Open), максимальну (High) та мінімальну (Low) ціну за день, а також обсяг торгів (Volume). Основним об'єктом моделювання є ціна закриття, оскільки вона найчастіше використовується в аналізі ринкових тенденцій та побудові прогнозних моделей. Саме цей показник відображає підсумкову вартість активу за день, враховуючи коливання ціни протягом торгової сесії.

Для забезпечення коректної роботи моделей, всі дані були нормалізовані за допомогою min-max нормалізації. Цей підхід дозволяє масштабувати значення змінних у діапазон від 0 до 1, що сприяє швидшій та стабільнішій конвергенції алгоритмів машинного навчання. Нормалізація також усуває проблему різного масштабу даних, оскільки ціни та обсяги торгів мають

різні одиниці вимірювання та величини, що може негативно впливати на точність моделей. Формула виглядає наступним чином:

$$X_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}. \quad (1)$$

де X – вихідне значення, $x_{\min}$ і $x_{\max}$ – мінімальне та максимальне значення змінної у вибірці відповідно, X_{norm} – нормалізоване значення.

Додавання нових ознак до моделі дозволяє враховувати додаткові патерни та взаємозв'язки у даних, які можуть бути важливими для точності прогнозування [10]. Тому було вирішено створити нові ознаки на основі наявної інформації, зокрема, до моделі були додані прості ковзні середні (Simple Moving Average, SMA) за 5 і 10 днів, які дозволяють врахувати коротко- та середньострокові тенденції в динаміці цін. Ковзна середня розраховується як середнє значення ціни закриття (Close) за відповідний період часу. Формула для розрахунку SMA:

$$SMA_n = \frac{1}{n} \sum_{i=1}^n x_i. \quad (2)$$

де n – кількість днів у періоді, X_i – ціна закриття на i -й день.

Окрім ковзних середніх, до моделі було вирішено включити лаги ціни закриття (Close), які відображають попередні значення цього показника та допомагають врахувати часові залежності в динаміці цін. Щоб визначити оптимальну кількість лагів, було проведено тестування автокореляційної функції (ACF) на 100 лагах. Результати показали, що всі 100 лагів є інформативними для моделювання, тому вони були обрані для використання. Це дозволяє моделі краще враховувати історичні патерни та покращити точність прогнозування.

Дані були розділені на тренувальну і тестову вибірки у співвідношенні 80:20, що відповідає 1120 дням у тренувальній вибірці та 280 дням у тестовій. Тренувальна вибірка охоплювала період з 20 квітня 2021 року по 13 травня 2024 року, а тестова – з 14 травня 2024 року по 17 лютого 2025 року. Такий розподіл забезпечує достатній обсяг даних для навчання моделі, дозволяючи їй виявити ключові закономірності, і водночас забезпечує значний період для перевірки її точності на нових даних.

Для моделювання часових рядів за допомогою нейронних мереж було використано два типи моделей з пакету Keras [11]: рекурентну нейронну мережу (RNN) та її вдосконалений варіант – довгу короткострокову пам'ять (LSTM). Рекурентні нейронні мережі є базовими моделями для роботи з часовими рядами, оскільки вони враховують залежності між даними, зберігаючи інформацію про попередні стани через зворотні зв'язки. Однак класичні RNN мають обмеження, пов'язані з «затуханням градієнтів», через що вони менш ефективні для задач, де важливі довгострокові залежності. LSTM, натомість, вирішує цю проблему завдяки використанню спеціальних блоків пам'яті, які дозволяють моделі зберігати інформацію протягом тривалих часових проміжків. Це дає можливість LSTM ефективно працювати з більш складними часовими структурами та враховувати як короткострокові, так і довгострокові залежності в даних.

Було вирішено побудувати обидві моделі для порівняння їхньої ефективності. RNN забезпечує швидше навчання завдяки своїй простішій структурі, що

є корисним для менш складних залежностей у даних. Водночас LSTM пропонує вищу гнучкість і точність для задач із більш вираженими нелінійними та довгостроковими патернами. Проведення такого порівняння дозволяє оцінити, яка з моделей є більш придатною для прогнозування цін криптовалют, враховуючи їхню високу волатильність і складну природу часових рядів.

Архітектура моделей включала два приховані шари. Перший шар складався з 64 нейронів, які обробляли вхідні послідовності даних, дозволяючи мережі зберігати інформацію про часові залежності. Другий шар містив 32 нейрони, які отримували оброблену інформацію з попереднього шару та фокусувалися на збереженні найважливіших ознак для прогнозування. У моделі також використовувались Dropout-шари для запобігання перенавчанню.

Модель тренувалася протягом 100 епох, при цьому дані не перемішувались під час навчання, щоб зберегти їхню часову структуру. Вихідний шар складався з одного нейрона, що генерував передбачуване значення ціни. Як функцію втрат було обрано середньоквадратичну похибку (MSE), яка є стандартом для задач регресії, а для оптимізації використовувався алгоритм Adam, що забезпечує ефективне та швидке навчання.

Для побудови моделей XGBoost та Random Forest були використані відповідно пакети xgboost [12] та randomForest [13]. Обидві моделі є ансамблевими методами, які використовують кілька базових моделей для поліпшення точності прогнозування.

Модель XGBoost, яка базується на методі градієнтного бустінгу, є ефективною для роботи з великими обсягами даних та складними структурами, оскільки вона будує послідовність дерев рішень, кожне з яких намагається виправити помилки попереднього. Для цієї моделі були визначені параметри, такі як максимальна глибина дерева, коефіцієнт навчання, частка вибірки для побудови дерева, а також частка ознак для кожного дерева. Модель була навчена на 100 етапах з раннім зупиненням, щоб уникнути перенавчання.

Модель Random Forest, також заснована на ансамблі дерев рішень, створює безліч дерев на випадкових підмножинах ознак і даних. Ключова різниця полягає в тому, що Random Forest використовує всі дерева паралельно, без коригування кожного дерева за допомогою попередніх, як у XGBoost. Для цієї моделі було встановлено 100 дерев та кількість ознак для кожного дерева, яка визначалась як квадратний корінь з кількості всіх ознак.

На основі результатів моделювання для шести криптовалют (Таблиці 1–6) можна зробити кілька загальних висновків. Загалом, LSTM та RNN демонструють кращу точність у порівнянні з XGBoost та Random Forest, що підтверджує ефективність рекурентних нейронних мереж для прогнозування криптовалютних цінкових рядів. Особливо стабільні результати показує LSTM, яка має хорошу точність для всіх активів, хоча в деяких випадках поступається іншим моделям.

Для Bitcoin і Binance найбільш ефективною моделлю виявилась LSTM. Ця модель продемонструвала стабільно хороші результати з найменшими значеннями показників помилок. Це підтверджує її ефективність при прогнозуванні цін на криптовалюту з високою волатильністю.

Для Ethereum і Litecoin більш ефективними виявились ансамблеві методи, такі як Random Forest (RF) та

XGBoost, відповідно. Обидві ці моделі демонструють високі результати, особливо щодо зниження показників помилок, таких як RMSE і MAE, що дозволяє зробити висновок про їхню перевагу при прогнозуванні цін для таких криптовалют.

Що стосується Cardano та Ripple, то найкращі результати продемонструвала модель RNN. Це підтверджується стабільністю й хорошими показниками точності для цих криптовалют. Моделі RNN, зокрема, добре адаптуються до характеру цінової динаміки цих активів, даючи точніші прогнози порівняно з іншими методами.

Загалом, LSTM демонструє стабільно хорошу точність, RNN у деяких випадках показує ще кращі результати, тоді як XGBoost та Random Forest у більшості випадків поступаються, хоча окремі результати вказують на їхню потенційну корисність. Це підкреслює важливість підбору моделі залежно від конкретного активу та його цінової динаміки.

Нижче наведені графіки найкращих моделей для кожної криптовалюти, де суцільна лінія відображає реальну ціну криптовалют, а пунктирна – модельовану. Ці графіки дозволяють візуально оцінити точність прогнозів, порівнюючи фактичні цінові рухи з тими, що були передбачені моделями.

Таблиця 1

Результати оцінки похибок моделей для Bitcoin

Модель	RMSE	MAE	MAPE
LSTM	3242.323	2507.386	0.03216601
RNN	7502.107	5722.197	0.07512642
XGBoost	20669.45	14037.59	0.2216055
Random Forest	20394.24	14310.76	0.2254016

Джерело: розраховано авторами

Таблиця 2

Результати оцінки похибок моделей для Ethereum

Модель	RMSE	MAE	MAPE
LSTM	129.0595	92.33241	0.02949628
RNN	95.5669	76.84762	0.02577145
XGBoost	101.5831	80.90424	0.02664282
Random Forest	83.65386	62.85203	0.02040538

Джерело: розраховано авторами

Таблиця 3
Результати оцінки похибок моделей для Binance

Модель	RMSE	MAE	MAPE
LSTM	23.86349	19.75814	0.03331136
RNN	40.97413	37.27494	0.06432165
XGBoost	94.10647	74.8424	0.140731
Random Forest	69.61916	49.79531	0.08829046

Джерело: розраховано авторами

Таблиця 4

Результати оцінки похибок моделей для Cardano

Модель	RMSE	MAE	MAPE
LSTM	0.04806679	0.04806679	0.06368051
RNN	0.0259426	0.0217168	0.04015369
XGBoost	0.04139044	0.02698291	0.04180627
Random Forest	0.0569587	0.03443315	0.04928099

Джерело: розраховано авторами

Таблиця 5

Результати оцінки похибок моделей для Ripple

Модель	RMSE	MAE	MAPE
LSTM	0.2683955	0.1427364	0.07855682
RNN	0.2507736	0.1389771	0.0767223
XGBoost	0.6625838	0.4479593	0.400474
Random Forest	0.7564215	0.4064302	0.3563429

Джерело: розраховано авторами

Таблиця 6

Результати оцінки похибок моделей для Litecoin

Модель	RMSE	MAE	MAPE
LSTM	3.647741	2.445624	0.02752569
RNN	4.375912	3.812795	0.04576178
XGBoost	3.140036	2.262489	0.02575395
Random Forest	6.000993	3.683487	0.0394304

Джерело: розраховано авторами

Прогнозовані значення для Bitcoin та Binance Coin моделі LSTM (Рисунок 1) показують результати, близькі до реальних, хоча в кінці періоду для Bitcoin спостерігається відхилення через різкий ріст ціни, тому прогнозовані значення виявились нижчими за




Рис. 1. Прогнозні моделі LSTM для Bitcoin та Binance coin

Джерело: розраховано авторами

реальні. Для Binance Coin модель також справилася з основними тенденціями, але через високі коливання ціни прогноз мав відхилення.

Графіки для Ethereum (Random Forest) і Litecoin (XGBoost) (Рисунок 2) демонструють значно кращі результати порівняно з іншими криптовалютами, що були спрогнозовані ансамблевими методами. Моделі добре справилися з прогнозуванням цін цих активів, відтворюючи основні тренди і динаміку.

Моделі RNN для Cardano і Ripple показали різні результати. Для Cardano модель мала певні відхилення на початку періоду, але добре спрогнозувала кінець. Натомість для Ripple, як і для Bitcoin, після різкого зросту ціни прогнозовані значення були нижчими за реальні. Незважаючи на це, саме ця модель виявилася найефективнішою серед усіх чотирьох використаних.

Висновки. У світі криптовалют наявність точних і надійних прогнозів курсу валют може виявитися критичною для інвесторів та учасників ринку. Дана стаття може бути надзвичайно корисною для тих, хто має намір вкладати свої кошти в криптовалютні активи, адже вона дозволить краще зрозуміти динаміку ринку, виявити основні тенденції та ризики, а також надати рекомендації щодо вибору

оптимальних стратегій інвестування в цей відносно новий, але динамічно розвиваючийся сектор фінансових послуг.

У цьому дослідженні було проведено порівняльний аналіз ефективності різних моделей для прогнозування цін шести криптовалют: Bitcoin, Ethereum, Binance Coin, Cardano, Ripple та Litecoin. Використано чотири основні моделі – LSTM, RNN, XGBoost та Random Forest, що дозволяють прогнозувати майбутні ціни на основі історичних даних.

Результати показали, що всі моделі продемонстрували досить близьку точність, проте є кілька цікавих відмінностей у їх ефективності для різних криптовалют. Модель LSTM виявилась особливо точною для прогнозування Bitcoin і Binance Coin, забезпечивши менші значення помилок, таких як RMSE та MAE, порівняно з іншими криптовалютами. Це свідчить про її здатність добре адаптуватися до високої волатильності цих активів.

Для криптовалют, таких як Ethereum і Litecoin, ансамблеві методи, зокрема XGBoost і Random Forest, показали кращі результати, зокрема через свою здатність до обробки великих обсягів даних і виявлення складних патернів. Вони продемонстрували стабільність і точність у прогнозах, особливо в умовах змішаної динаміки цін цих криптовалют.




Рис. 2. Прогнозні моделі Random Forest для Ethereum та XGBoost для Litecoin

Джерело: розраховано авторами




Рис. 3. Прогнозні моделі RNN для Cardano та Ripple

Джерело: розраховано авторами

Найкращою моделлю для прогнозування Cardano та Ripple виявилася RNN. Завдяки своїй здатності ефективно обробляти послідовні залежності та вловлювати динаміку змін у часових рядах, RNN забезпечила вищу точність порівняно з іншими методами.

Загалом, для кожної криптовалюти були виявлені моделі, що найбільше підходять для прогнозування її цінової динаміки, залежно від характеру волатильності

та специфіки ринку. У подальших дослідженнях може бути корисним поєднання різних моделей або застосування методів ансамблю для покращення результатів прогнозування.

Отже, дослідження показало, що вибір моделі для прогнозування криптовалют варто проводити з урахуванням специфіки кожної криптовалюти, а також її ринкових особливостей, таких як волатильність і історичні тренди.

Література:

1. Jin C, Li Y. Cryptocurrency Price Prediction Using Frequency Decomposition and Deep Learning. *Fractal and Fractional*. 2023. No. 7 (10). DOI: <https://doi.org/10.3390/fractalfract7100708>
2. Kiranmai Balijepalli, N.S.S. and Thangaraj, V. Prediction of cryptocurrency's price using ensemble machine learning algorithms. *European Journal of Management and Business Economics*, 2025. Vol. ahead-of-print No. ahead-of-print. DOI: <https://doi.org/10.1108/EJMBE-08-2023-0244>
3. Lean Yu, Shouyang Wang, Kin Keung Lai. Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm. *Energy Economics*, 2008, Vol. 30, Is. 5, P. 2623-2635. DOI: <https://doi.org/10.1016/j.eneco.2008.05.003>
4. Ahmed Bouteska, Mohammad Zoynul Abedin, Petr Hajek, Kunpeng Yuan. Cryptocurrency price forecasting – A comparative analysis of ensemble learning and deep learning methods. *International Review of Financial Analysis*. 2024. Vol. 92. DOI: <https://doi.org/10.1016/j.irfa.2023.103055>
5. Kleban, Y., Stasiuk, T. Crypto Currency Price Forecast: Neural Network Perspectives. *Visnyk of the National Bank of Ukraine*, 2022. No. 254, P. 29–42. DOI: <https://doi.org/10.26531/vnbu2022.254.03>
6. Nandan S & Usha Sree R. Cryptocurrency Price Prediction using Machine Learning. 2024. DOI: <https://doi.org/10.48175/IJARST-22530>
7. Wen, Ng & Ling, Lew. Evaluation of Cryptocurrency Price Prediction Using LSTM and CNNs Models. *JOIV : International Journal on Informatics Visualization*. 2023. No. 7. DOI: <https://doi.org/10.30630/joiv.7.3-2.2344>
8. Omole, O., Enke, D. Deep learning for Bitcoin price direction prediction: models and trading strategies empirically compared. *Financ Innov*. Vol. 10, Is. 117 (2024). DOI: <https://doi.org/10.1186/s40854-024-00643-1>
9. D Siddharth, Jitendra Kaushik. Cryptocurrency Price Prediction Using Deep Learning and Machine Learning. 2022. URL: <https://easychair.org/publications/preprint/4SV7>
10. Jatoth C, Jain R, Fiore U, Chatharasupalli S. Improved Classification of Blockchain Transactions Using Feature Engineering and Ensemble Learning. *Future Internet*. 2022. No. 14(1). DOI: <https://doi.org/10.3390/fi14010016>
11. Allaire J, Chollet F. keras: R Interface to 'Keras'. R package version 2.15.0. 2024. URL: <https://CRAN.R-project.org/package=keras>
12. Chen T, He T, Benesty M, Khotilovich V, Tang Y, Cho H, Chen K, Mitchell R, Cano I, Zhou T, Li M, Xie J, Lin M, Geng Y, Li Y, Yuan J. xgboost: Extreme Gradient Boosting. R package version 1.7.7.1. 2024. URL: <https://CRAN.R-project.org/package=xgboost>
13. A. Liaw and M. Wiener. Classification and Regression by random Forest. *R News*. 2002. No. 2 (3), P. 18–22. URL: <https://cran.r-project.org/package=randomForest>

Стаття надійшла до редакції 04.03.2025

Стаття опублікована 15.04.2025