

tion processes and ensuring sustainable recovery of Ukraine: the potential of the fund for Ukraine]. *Ekonomika, menedzhment ta pravo*, 9, 22–30. <https://doi.org/10.33251/2707-8620-2025-9-22-30>

Tykhonova D. S. (2024). Derzhavna stratehiia rozvytku v ramkakh Planu Ukraine Facility [State development strategy within the Ukraine Facility Plan]. *Yurydychnyi naukovyi elektronnyi zhurnal*, 9, 271–273. <https://doi.org/10.32782/2524-0374/2024-9/63>

Wesseling J. H. & Edquist C. (2018). Public procurement for innovation to help meet societal challenges: A review and case study. *Science and Public Policy*, 4(45), 493–502. <https://ideas.repec.org/a/oup/scip-pl/v45y2018i4p493-502.html>

World Bank. (2022). Procurement Framework. <https://www.worldbank.org/en/projects-operations/products-and-services/brief/procurement-new-framework>

The World Bank. (2017). World Reconstruction Conference (3rd ed.). *The World Bank*. <https://www.gfdrr.org/wrc3>

World Bank. (2025). Assessing Value for Money of the PPP Public Private Partnership. <https://ppp.worldbank.org/assessing-value-money-ppp>

WTO. (2014). Agreement on Government Procurement 2012 and related WTO legal texts. *WTO, Geneva*. [https://www.wto.org/english/docs\\_e/legal\\_e/rev-gpr-94\\_01\\_e.pdf](https://www.wto.org/english/docs_e/legal_e/rev-gpr-94_01_e.pdf)

Yefymenko T. I. (2023). Upravlinnia derzhavnymy finansamy v period voiennoho stanu [Public finance management during martial law]. *Finansy Ukrainy*, 1, 7–25. <https://doi.org/10.33763/finukr2022.04>

Стаття надійшла до редакції / Received: 11.01.2026 р.  
Статтю прийнято до публікації / Accepted: 25.01.2026 р.  
Оприлюднено / Published: 25.02.2026 р.

УДК 336.71:004.8  
JEL: C38; C45; G17  
DOI: <https://doi.org/10.32983/2222-4459-2026-1-439-449>

## ГІБРИДНИЙ ПІДХІД ДО МОДЕЛЮВАННЯ ДИНАМІКИ РИНКУ КРИПТОВАЛЮТ НА ОСНОВІ КЛАСТЕРНОГО АНАЛІЗУ ТА НЕЙРОМЕРЕЖЕВИХ ТЕХНОЛОГІЙ

© 2026 КОЧОРБА В. Ю.

УДК 336.71:004.8  
JEL: C38; C45; G17

### Кочорба В. Ю. Гібридний підхід до моделювання динаміки ринку криптовалют на основі кластерного аналізу та нейромережових технологій

Метою статті є розробка та практична апробація комплексу моделей аналізу динаміки ринку криптовалют, що базується на поєднанні методів інтелектуального аналізу даних (Data Mining) та глибокого навчання (Deep Learning). Актуальність дослідження зумовлена високою волатильністю криптоактивів і неефективністю традиційних економетричних підходів в умовах нелінійності ринкових процесів. У роботі використано методи описової статистики та кореляційного аналізу для формування простору ознак; метод кластерного аналізу *k*-середніх (*k*-means) для класифікації криптовалют за рівнем інвестиційної привабливості; архітектури штучних нейронних мереж (ANN) та мереж довгої короткострокової пам'яті (LSTM) для прогнозування часових рядів вартості активів. Обробка даних, навчання моделей та візуалізація результатів здійснювалися мовою програмування Python з використанням бібліотек Pandas, Scikit-learn, Keras та TensorFlow. Проведено кластеризацію ринку криптовалют на основі показників капіталізації, волатильності й історичної прибутковості. Визначено оптимальну кількість кластерів ( $k=5$ ) та підтверджено якість розбиття за допомогою коефіцієнта силуету (0,53). Виявлено, що найбільш привабливими для інвестування є активи 5-го кластера (висока прибутковість, помірний ризик, представник – Ахіе) та 3-го кластера (низький ризик, консервативна стратегія, представник – WBTC). Для монет-репрезентантів цих кластерів побудовано та навчено нейромережові моделі. Встановлено, що модель LSTM демонструє вищу точність порівняно з класичною ANN, досягаючи коефіцієнта детермінації  $R^2 > 0,93$  та меншої середньоквадратичної похибки (MSE) на тестових даних. Доведено ефективність застосування «вентилів забування» у LSTM для фільтрації ринкового шуму та виявлення довгострокових трендів. Запропонований гібридний підхід дозволяє автоматизувати процес відбору активів для інвестування та підвищити точність прогнозування їхньої ринкової вартості. Отримані результати можуть бути використані як основа для побудови алгоритмічних торгових стратегій і систем підтримки прийняття рішень в управлінні інвестиційними портфелями.

**Ключові слова:** фінансовий ринок, ринок криптовалют, кластерний аналіз, *k*-means, нейронні мережі, LSTM, прогнозування, інвестиційна стратегія.

Рис.: 10. Бібл.: 16.

Кочорба Валерія Юріївна – кандидат економічних наук, доцент, заступник директора, Навчально-науковий інститут «Каразінський банківський інститут» Харківського національного університету імені В. Н. Каразіна (просп. Перемоги, 55, Харків, 61174, Україна)

E-mail: [v.y.kochorba@karazin.ua](mailto:v.y.kochorba@karazin.ua)

ORCID: <https://orcid.org/0000-0002-5509-680X>

Scopus Author ID: 59253138000

**Kochorba V. Yu. A Hybrid Approach to Modeling Cryptocurrency Market Dynamics Based on Cluster Analysis and Neural Network Technologies**

The aim of the article is to develop and practically test a set of models for analyzing the dynamics of the cryptocurrency market, based on a combination of data mining and deep learning methods. The relevance of the research is determined by the high volatility of crypto assets and the inefficiency of traditional econometric approaches in conditions of nonlinear market processes. The study employs descriptive statistics and correlation analysis methods to form the feature space; the k-means clustering method to classify cryptocurrencies by investment attractiveness; architectures of artificial neural networks (ANN) and long short-term memory (LSTM) networks to forecast time series of asset values. Data processing, model training, and result visualization were carried out using the Python programming language with the Pandas, Scikit-learn, Keras, and TensorFlow libraries. A clustering of the cryptocurrency market was performed based on capitalization, volatility, and historical profitability indicators. The optimal number of clusters was determined ( $k=5$ ), and the quality of the clustering was confirmed using the silhouette coefficient (0.53). It was found that the most attractive assets for investment are those in cluster 5 (high profitability, moderate risk, representative – Axie) and cluster 3 (low risk, conservative strategy, representative – WBTC). Neural network models were created and trained for the representative coins of these clusters. It was found that the LSTM model demonstrates higher accuracy compared to the classical ANN, achieving a coefficient of determination  $R^2 > 0,93$  and a lower mean squared error (MSE) on the test data. The efficiency of applying «forget gates» in LSTM for filtering market noise and identifying long-term trends was demonstrated. The proposed hybrid approach enables the automation of the asset selection process for investment and enhances the accuracy of predicting their market value. The resulting findings can serve as a foundation for developing algorithmic trading strategies and decision support systems in investment portfolio management.

**Keywords:** financial market, cryptocurrency market, cluster analysis, k-means, neural networks, LSTM, forecasting, investment strategy.

**Fig.:** 10. **Bibl.:** 16.

**Kochorba Valeriia Yu.** – PhD (Economics), Associate Professor, Deputy Director, Educational and Scientific Institute «Karazin Banking Institute» of V. N. Karazin Kharkiv National University (55 Peremohy Ave., Kharkiv, 61174, Ukraine)

**E-mail:** v.y.kochorba@karazin.ua

**ORCID:** <https://orcid.org/0000-0002-5509-680X>

**Scopus Author ID:** 59253138000

В умовах стрімкої цифровізації світової економіки ринок криптовалют трансформується з нішевого технологічного експерименту у повноцінний сегмент глобальної фінансової системи [2]. Висока волатильність криптоактивів, відсутність централізованого регулювання та значний вплив спекулятивних факторів роблять традиційні економічні методи прогнозування малоефективними. Класичні моделі часто не здатні коректно інтерпретувати нелінійні залежності, хаотичну природу котирувань та «ефект пам'яті» у часових рядах цін криптовалют.

Велика кількість доступних для торгівлі активів (понад 10 000 монет) створює проблему вибору для інвестора, оскільки ручний аналіз кожного активу є неможливим. Це актуалізує пошук нових, гібридних підходів, які поєднують методи інтелектуального аналізу даних для попередньої селекції активів (кластеризацію) та методи глибокого машинного навчання (Deep Learning) для безпосереднього прогнозування їхньої вартості.

Питання класифікації фінансових активів, зокрема дослідження ролі криптовалют як повноцінного фінансового активу, висвітлено у роботах [6]. Водночас ефективність методів машинного навчання та глибокого навчання (Deep Learning) для аналізу та сегментації ринкових даних у контексті прогнозування цін на криптовалюту обґрунтували [5].

Особливості застосування рекурентних нейронних мереж (RNN) для аналізу часових рядів та

прогнозування ринкових показників є центальною темою багатьох досліджень. Архітектура LSTM (Long Short-Term Memory) є однією з найбільш ефективних для роботи з фінансовими часовими рядами. Її використання, часто в поєднанні з GRU та бінаправленими LSTM (Bi-LSTM) моделями, для точного прогнозування цін на криптовалюту детально досліджено [7; 13; 15]. Порівняльний аналіз підходів, що використовують RNN, включаючи LSTM, також наведений у працях [8; 12; 14].

Більшість існуючих прикладних досліджень зосереджуються або виключно на біткоїні, ігноруючи специфіку альткоїнів, або застосовують методи прогнозування до всього масиву активів без попередньої оцінки їхньої інвестиційної якості. Таким чином, невирішеною залишається проблема побудови комплексної моделі, яка б дозволяла спочатку класифікувати активи за рівнем ризику та дохідності, відсіюючи неефективні, а вже потім будувати прогноз для найбільш привабливих криптовалют.

**Метою статті** є розробка та апробація гібридного підходу до аналізу динаміки ринку криптовалют, який, з урахуванням концептуальної схеми дослідження, базується на послідовному обґрунтуванні інформаційного простору ознак, побудові моделі класифікації криптовалют за рівнем інвестиційної привабливості на основі методів кластерного аналізу та розробці моделей прогнозування динаміки ринкової вартості з використанням не-

йромережових технологій, що в сукупності дозволить підвищити якість управлінських рішень при формуванні інвестиційних портфелів.

**М**етодологія дослідження полягала у застосуванні гібридного підходу, який послідовно поєднує методи інтелектуального аналізу даних та глибокого навчання. На першому етапі використовувалися методи описової статистики та кореляційного аналізу для формування простору ознак, а також проводилася нормалізація даних методом MinMaxScaler для усунення проблеми різної розмірності. Для класифікації криптовалют за рівнем інвестиційної привабливості застосовувався метод ітеративного кластерного аналізу *k*-середніх (*k*-means), який дозволив обрати найбільш привабливі активи, що мають оптимальне співвідношення прибутковості та волатильності. На третьому етапі для криптовалют-репрезентантів кластерів із високим інвестиційним потенціалом розроблялися моделі прогнозування динаміки ринкової вартості з використанням архітектур штучних нейронних мереж (ANN) та мереж довгої короткострокової пам'яті (LSTM).

У контексті високої волатильності ринку, для ефективного управління інвестиційними ризиками необхідним є застосування інструментів, що забезпечують об'єктивну оцінку динаміки активів. З огляду на це, першочерговим етапом дослідження є візуальний та кількісний аналіз ключових представників крипторинку, що дозволяє ідентифікувати спільні тренди та диференційні характеристики їхньої цінової поведінки [4].

Таким чином, з метою деталізації предметної області та ілюстрації цінових тенденцій у часі, на рис. 1 представлена композиція з чотирьох окремих графіків, які ілюструють нормалізовану динаміку цін чотирьох популярних криптовалют: Bitcoin (BTC), Ripple (XRP), Dash (DASH) та Litecoin (LTC).

Аналіз нормалізованих часових рядів цін, представлених на рисунку 1, дозволяє встановити суттєву гетерогенність цінової динаміки між окремими криптовалютами протягом досліджуваних періодів. Зокрема, Bitcoin (BTC) демонструє найвищий коефіцієнт зростання і пікове значення серед усіх активів, що підкреслює його статус як основного драйвера ринку. На відміну від BTC, DASH та LTC характеризуються високою волатильністю на початку 2022 року з подальшою тривалою стагнацією та поверненням до значень, близьких до базового рівня. У свою чергу, XRP демонструє найбільш стабільний та поступальний висхідний тренд протягом останніх п'яти років. Це свідчить про необхідність диференційованого підходу до

оцінки ризиків та інвестиційного потенціалу для кожної з проаналізованих криптовалют [6; 10].

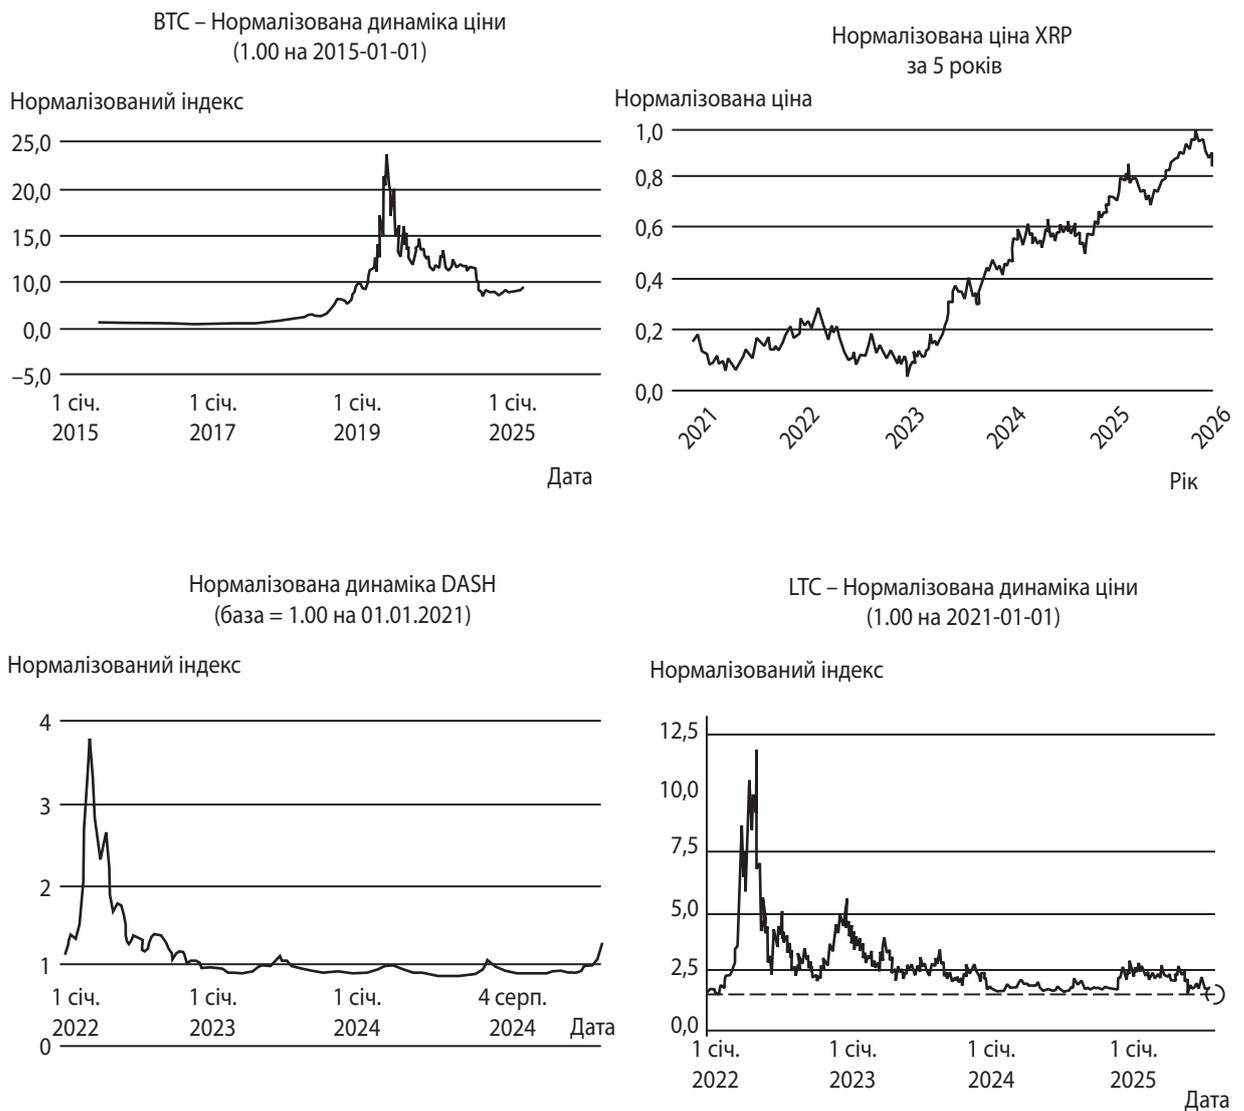
Концептуальна схема дослідження включає три основні етапи, що представлено на рис. 2.

Цільовою спрямованістю *першого етапу* є обґрунтування інформаційного простору ознак дослідження. З цією метою здійснюється огляд відкритих баз даних, що дозволяють сформувати максимально повну базу ретроспективної інформації про стан ринку криптовалют. Серед ключових індикаторів, що використовуються на цьому етапі, виділяються ринкова капіталізація, рівень прибутковості інвестицій у криптовалюту, а також рівень волатильності [5]. Для уточнення цієї системи індикаторів проводиться оцінка інформативності з використанням методу дисперсійного аналізу.

На *другому етапі* дослідження (відповідно до схеми) розробляється модель класифікації криптовалют за рівнем інвестиційної привабливості. Для побудови цієї моделі застосовується метод ітеративного кластерного аналізу, а саме метод *k*-середніх. Реалізація моделі класифікації здійснюється за допомогою програмних середовищ. Побудова моделі класифікації дає можливість обрати ті криптовалюти, які мають найбільш привабливе для інвестора співвідношення прибутковості та волатильності, а також сформувати фільтр для відсіювання активів із низьким рівнем інвестиційної привабливості [7].

На *третьому етапі* для криптовалют-репрезентантів кластерів із високим рівнем інвестиційної привабливості розробляються моделі прогнозування динаміки ринкової вартості [1; 3]. В якості основи для цих моделей використовуються методи аналізу часових рядів (включаючи адаптивні методи, ARIMA-моделі тощо) та моделі нейронних мереж. В рамках цього етапу проводиться порівняльний аналіз інструментарію та формуються рекомендації щодо вибору найбільш ефективного методу для побудови моделі прогнозування динаміки вартості криптовалют. Для оцінки розроблених моделей застосовуються наступні критерії: MSE (середньоквадратична похибка),  $R^2$  (коефіцієнт детермінації) та SR (Success rate – процент вгаданих трендів). Результатом третього етапу є комплекс нейромережових моделей динаміки ринкової вартості криптовалют-репрезентантів та рекомендації щодо вибору методу прогнозування.

**А** дослідження проводилося у три послідовні етапи, відповідно до концептуальної схеми дослідження: 1) формування інформаційного простору ознак та попередня обробка даних; 2) кластеризація криптовалют для виявлення груп з найвищим інвестиційним потенціалом; 3) побу-



**Рис. 1. Нормалізована динаміка цін BTC, XRP, DASH та LTC**

**Джерело:** побудовано автором на основі [10].

дова та порівняльний аналіз прогнозних моделей на базі штучних нейронних мереж (ANN) та мереж довгої короткострокової пам'яті (LSTM).

1. Обґрунтування інформаційного простору та попередня обробка даних.

Для проведення дослідження було сформовано вибірку, що включає ключові фінансові показники криптовалют. Інформаційною базою послугували історичні дані торгів [10]. До переліку вхідних змінних було включено: ринкову капіталізацію (MarketCap), ціну закриття (Last), обсяг торгів (TradedVol), волатильність (Volatility), а також показники прибутковості за різні періоди (3 місяці, 6 місяців, з початку року та річну прибутковість).

Первинний аналіз даних виявив проблему різної розмірності ознак. Наприклад, капіталізація біткоїна вимірюється сотнями мільярдів доларів, тоді як ціна окремих альткоїнів може становити частки цента. Для усунення цього дисбалансу та

забезпечення коректної роботи алгоритмів машинного навчання було застосовано нормалізацію даних методом MinMaxScaler (рис. 3), що дозволило привести всі значення до діапазону [0, 1] без спотворення структури розподілу даних.

**Н**ормалізація даних методом MinMaxScaler була застосована для стандартизації вихідної інформації, що включала ринкову капіталізацію, ціну закриття, обсяг торгів та волатильність, з метою усунення проблеми різної розмірності ознак. Метод забезпечує збереження форми оригінального розподілу даних і не призводить до значної зміни інформації, вбудованої у вихідні дані.

На основі побудованої кореляційної матриці було виявлено істотний зв'язок між рівнем волатильності та короткостроковою прибутковістю активів, що підтверджує гіпотезу про спекулятивний характер ринку криптовалют у короткостроковій

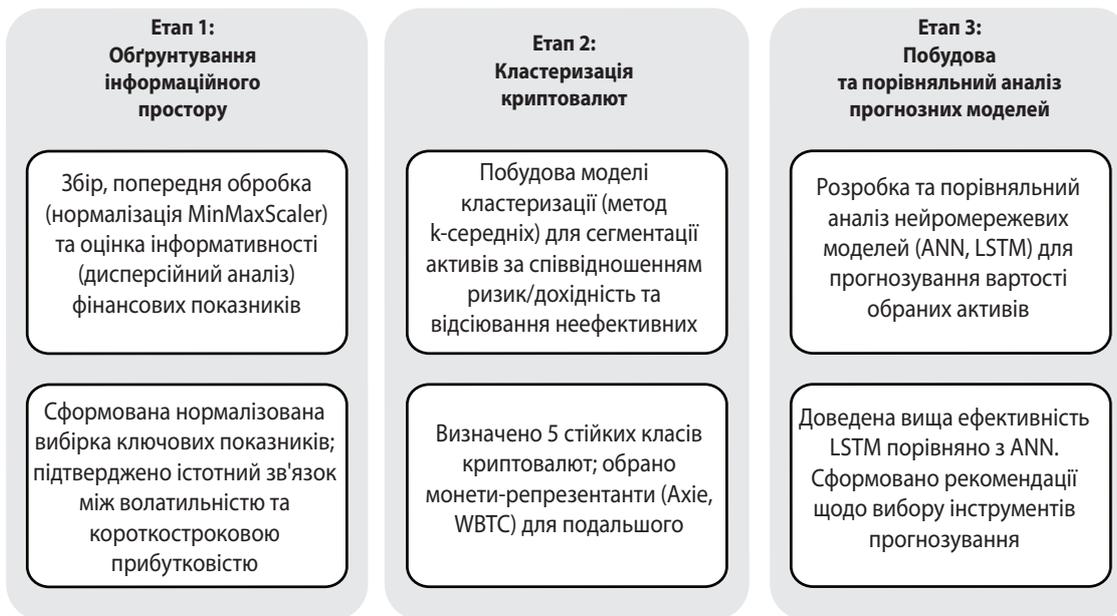


Рис. 2. Концептуальна схема дослідження

Джерело: систематизовано автором на основі [2; 3; 6; 12; 15].

	CURRENCY	MKT CAP	FD MKT CAP	LAST	AVAIL COINS	TOTAL COINS	TRADED VOL	CHG %	3-MONTH PERF	6-MONTH PERF	YTD PERF	YEARLY PERF	VOLATILITY
0	Bitcoin	1.000000	1.000000	9.996716e-01	1.082279e-04	3.296937e-05	0.445709	0.226379	0.076186	0.047809	4.624122e-03	0.012701	0.090481
1	Ethereum	0.443949	0.398753	7.108078e-02	6.818132e-04	1.866118e-04	0.204341	0.168526	0.082394	0.040856	1.977341e-02	0.038599	0.146514
2	Binance Coin	0.086240	0.077338	1.010676e-02	9.612774e-04	2.631057e-04	0.037147	0.236744	0.095480	0.037299	6.230556e-02	0.094343	0.225142
3	Tether	0.057954	0.053787	1.381848e-05	4.259233e-01	1.205238e-01	1.000000	0.254486	0.029482	0.024189	8.746556e-07	0.000016	0.003964
4	Solana	0.055405	0.085514	3.646944e-03	1.747913e-03	8.032298e-04	0.035055	0.113191	0.358029	0.176024	5.872554e-01	0.477501	0.218023
5	Cardano	0.052620	0.064829	2.984278e-05	1.920216e-01	7.102899e-02	0.028099	0.202535	0.026785	0.024720	3.883613e-02	0.080897	0.220464
6	XRP	0.042784	0.084825	1.651842e-05	2.719486e-01	1.578424e-01	0.041390	0.219548	0.028846	0.011762	1.673518e-02	0.014256	0.086078
7	Polkadot	0.033985	0.034325	7.106482e-04	5.694416e-03	1.741305e-03	0.017024	0.122336	0.132473	0.030094	1.498155e-02	0.039818	0.226078
8	HEX	0.032908	0.116070	2.131232e-06	1.000000e+00	1.000000e+00	0.000000	0.291447	0.097487	0.198857	4.732721e-02	0.118510	0.843129
9	Dogecoin	0.025362	0.022637	2.289138e-06	7.618519e-01	2.085313e-01	0.020647	0.277525	0.008177	0.002692	2.126280e-01	0.403495	0.275036
10	USD Coin	0.025181	0.022474	1.382113e-05	1.985125e-01	5.433611e-02	0.050503	0.255517	0.029522	0.024231	9.549832e-06	0.000024	0.002312

Рис. 3. Нормалізація даних методом MinMaxScaler

Джерело: розраховано автором на основі [6; 8].

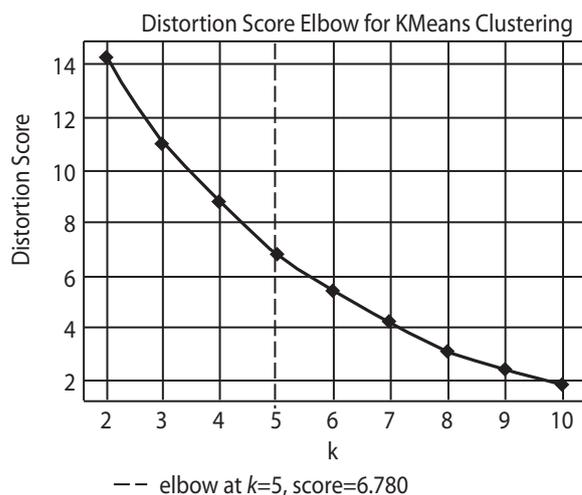
перспективі. Водночас для середньострокового періоду (6 місяців – 1 рік) кореляція між ризиком та прибутковістю стає більш збалансованою.

## 2. Кластерний аналіз ринку криптовалют.

Для сегментації ринку та виділення груп активів із подібними характеристиками використано метод  $k$ -середніх ( $k$ -means). Це ітеративний алгоритм, який мінімізує сумарне квадратичне відхилення точок кластерів від їхніх центрів. Критично важливим етапом є визначення оптимальної кількості кластерів ( $k$ ). Для цього було застосовано метод «кам'янистого осипу» (Elbow Method) [11]. Як видно з наведеного нижче графіка (рис. 4), різке уповільнення зниження суми внутрішньокластерних відстаней (distortion score) спостерігається у точці  $k = 5$ .

Графік «кам'янистого осипу» був використаний для визначення оптимальної кількості кластерів у моделі, оскільки метод  $k$ -середніх вимагає попереднього задання числа кластерів. На графіку чітко видно, що слід використовувати 5 кластерів, оскільки різке уповільнення зниження суми внутрішньокластерних відстаней спостерігається саме у цій точці.

Якість отриманого розбиття перевірено за допомогою коефіцієнта силуету (Silhouette Score), який показує, наскільки об'єкт схожий на свій власний кластер порівняно з іншими кластерами (рис. 5). Середнє значення силуету склало 0.53, що свідчить про достатню щільність та відокремленість отриманих кластерів. Більшість об'єктів мають позитивні значення силуету, що підтверджує



**Рис. 4. Графік кам'янистого осипу**

**Джерело:** побудовано автором на основі [8; 10].

коректність їх віднесення до відповідних груп. Показник силуету застосовувався для оцінки якості отриманого розбиття, де позитивні значення, близькі до 1, свідчать про правильне призначення елемента до кластера та його достатню щільність.

Середнє значення силуету, яке склало 0.53, підтверджує коректність розподілу елементів, хоча лише один кластер виявився більшим за середнє значення.

Аналіз центроїдів (середніх значень ознак) дозволив інтерпретувати економічний зміст виділених 5 кластерів:

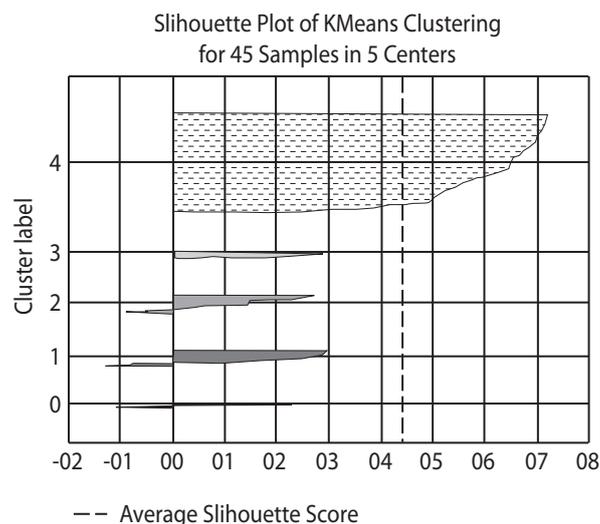
Кластер 5 (монета-представник – Axie): Характеризується найвищими показниками прибутковості у середньостроковій перспективі (6–12 місяців) при помірному рівні ризику. Це найбільш привабливий кластер для агресивного інвестора.

Кластер 3 (монета-представник – WBTC): Активи з найменшими показниками прибутковості, але й найнижчим рівнем ризику. Це консервативні активи, що корелюють з базовим активом ринку (Bitcoin).

Кластер 1 (монета-представник – Decentraland): Активи з середніми значеннями прибутковості та волатильності, які демонструють потенціал до зростання.

Інші кластери (0, 2, 4) виявилися менш привабливими для інвестування через дисбаланс ризику та дохідності або низьку ліквідність (рис. 6).

Графік середніх значень за кластерами (центроїдів) дозволяє інтерпретувати економічний зміст виділених груп активів та їхню інвестиційну привабливість. Найбільш привабливими для інвестора визнано криптовалюти кластера 5 (висо-



**Рис. 5. Показник силуету**

**Джерело:** побудовано автором на основі [5; 6; 8].

ка прибутковості у середньостроковій перспективі при відносно низькій волатильності), кластера 1 (середні показники) та кластера 3 (найменші показники прибутковості та найнижчий рівень ризику). На основі аналізу центроїдів було обрано репрезентантів цих кластерів (Decentraland, WBTC, Axie) для подальшого прогнозування, оскільки вони мають найменшу евклідову відстань до центру кластера. На основі розрахованих евклідових відстаней до центроїдів для подальшого етапу прогнозування було обрано монети-репрезентанти найбільш перспективних кластерів: Decentraland (Кластер 1), WBTC (Кластер 3) та Axie (Кластер 5).

3. Нейромережеве моделювання динаміки вартості.

Для прогнозування часових рядів обраних активів було розроблено та протестовано дві архітектури нейронних мереж:

ANN (Artificial Neural Network) – класичний багатоваріантний перцептрон прямого поширення (рис. 7).

LSTM (Long Short-Term Memory) – рекурентна нейронна мережа, архітектура якої дозволяє навчатися на довгострокових залежностях, що є критично важливим для фінансових часових рядів, які мають «пам'ять».

Дані було розділено на навчальну (70%) та тестову (30%) вибірку. Навчання проводилося протягом 100 епох з використанням оптимізатора Adam та функції втрат MSE (Mean Squared Error).

Моделювання для монети Decentraland (кластер з середнім ризиком) показало високу ефективність обох моделей.

Plot of Means for Each Cluster

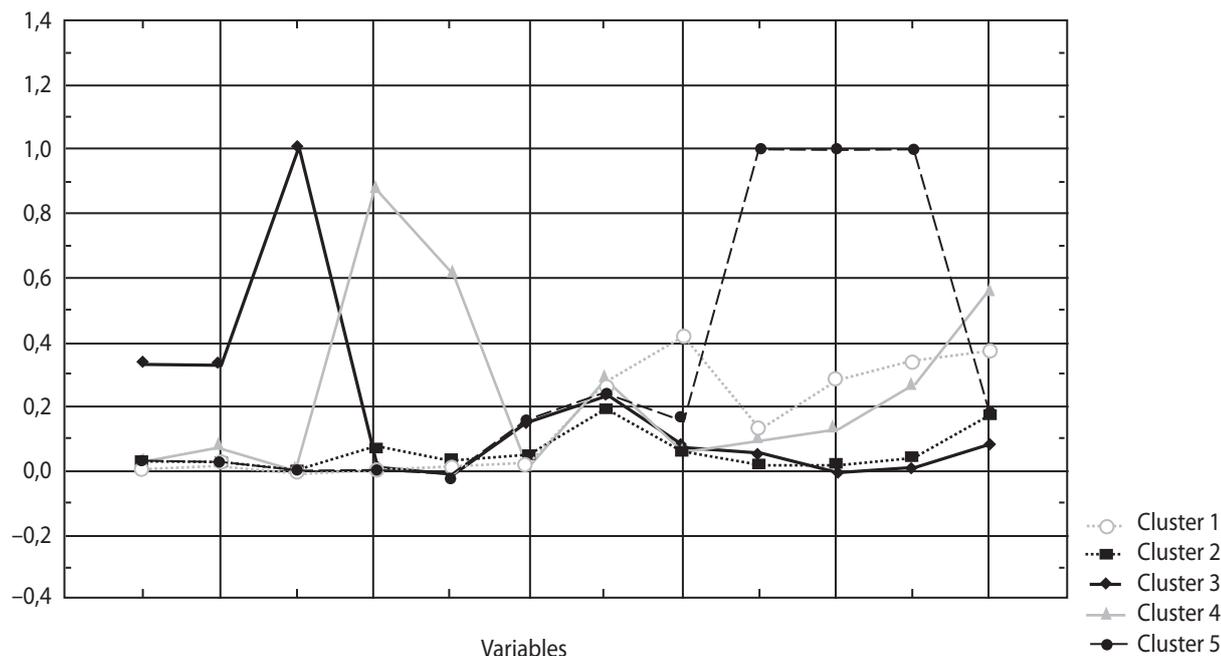


Рис. 6. Графік середніх за кластерами

Джерело: розраховано автором на основі [6; 8].

```
# Простая искусственная нейронная сеть ANN для прогнозирования временных рядов
ann=Sequential()
ann.add(Dense(12, input_dim=1, activation='relu'))
ann.add(Dense(1))
ann.compile(loss='mean_squared_error', optimizer='adam')
early_stop = EarlyStopping(monitor='loss', patience=2, verbose=1)
history= ann.fit(X_train, y_train, epochs=100, batch_size=1, verbose=1, callbacks=[early_stop], shuffle=False)

Epoch 1/100
1184/1184 [=====] - 2s 1ms/step - loss: 0.0008
Epoch 2/100
1184/1184 [=====] - 1s 1ms/step - loss: 0.0028
Epoch 3/100
1184/1184 [=====] - 1s 1ms/step - loss: 0.0020
Epoch 4/100
1184/1184 [=====] - 1s 1ms/step - loss: 0.0018
Epoch 5/100
1184/1184 [=====] - 1s 1ms/step - loss: 0.0017
Epoch 6/100
1184/1184 [=====] - 1s 1ms/step - loss: 0.0016
```

Рис. 7. Навчання моделі ANN

Джерело: розраховано автором на основі [16].

Графіки навчання демонструють швидке зниження функції втрат, що свідчить про адекватність обраної архітектури. Цей графік демонструє процес навчання класичної штучної нейронної мережі (ANN), який проводився протягом 100 епох з використанням функції втрат — середньоквадратичної помилки (MSE) та оптимізатора Adam. Швидке зниження функції втрат, яке відображає графік,

свідчить про адекватність обраної архітектури для прогнозування часових рядів.

Оцінка якості моделей проводилася за коефіцієнтом детермінації ( $R^2$ ). Для монети Decentraland:

- ✦  $R^2$  моделі ANN на тестовій вибірці склав 0,898.
- ✦  $R^2$  моделі LSTM склав 0,895.

Незважаючи на близькі статистичні показники, візуальний аналіз графіків прогнозів показує, що LSTM краще відтворює локальні тренди та менш схильна до перенавчання на шумі (рис. 8).

Наведений рисунок ілюструє порівняльні результати прогнозування динаміки вартості криптовалюти, отримані за допомогою двох архітектур нейронних мереж: штучної нейронної мережі прямого поширення (ANN) та

рекурентної нейронної мережі довгої короткострокової пам'яті (LSTM).

Модель ANN візуалізує результат прогнозування, отриманий у порівнянні з фактичними даними на тестовій вибірці. Незважаючи на отриманий високий коефіцієнт детермінації, модель ANN продемонструвала меншу здатність коректно відтворювати локальні ринкові тренди, особливо у порівнянні з результатами, отриманими за допомогою LSTM.

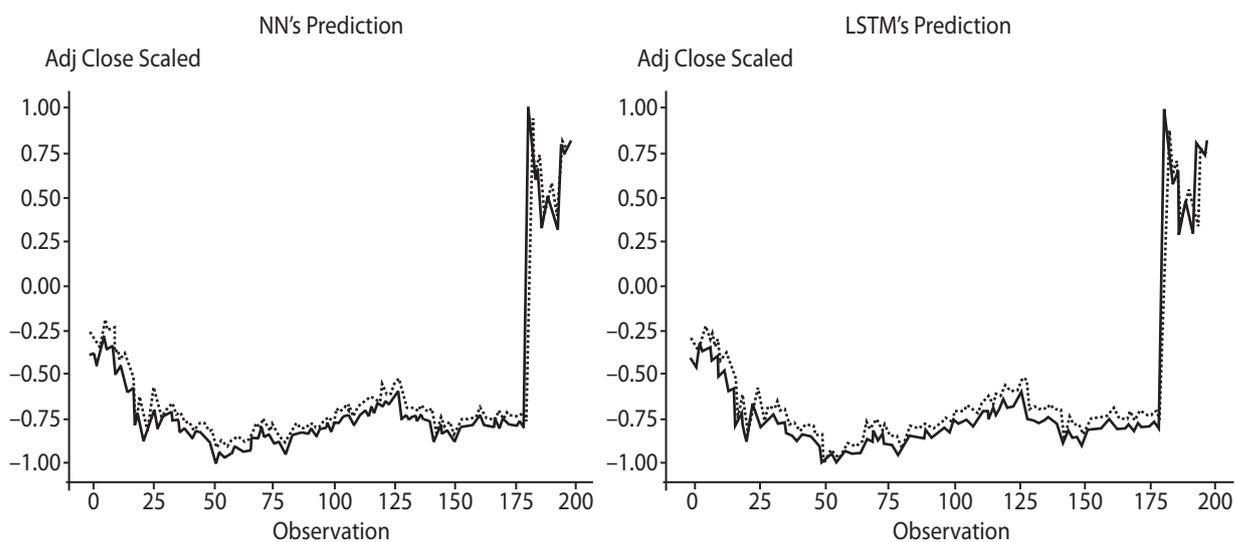


Рис. 8. Графіки фактичних та прогнозних даних ANN і LSTM

Джерело: побудовано автором на основі [16].

На протипагу цьому, модель LSTM (Long Short-Term Memory) краще пристосована для навчання на довгострокових залежностях у часових рядах фінансових активів, що мають «пам'ять». Її архітектура, що включає спеціалізовані блоки, такі як «вентилі забування» (*forget gates*), дозволяє мережі ефективно ігнорувати нерелевантний короткостроковий шум і фокусуватися на значущих довгострокових трендах. Завдяки цій архітектурній перевазі модель LSTM виявила здатність краще відтворювати локальні тренди та була менш схильною до перенавчання на ринковому шумі [9]. Ця вища точність підтверджується високими значеннями коефіцієнта детермінації, наприклад, досягаючи на тестових даних.

Найбільш показовими є результати моделювання для високоволатильного активу Ахіе (найпривабливіший кластер №5). Тут перевага архітектури LSTM стала очевидною. Порівняння метрик якості моделей наведено нижче:

ANN:  $R^2 = 0,930$ ,  $MSE = 0,022$ .

LSTM:  $R^2 = 0,939$ ,  $MSE = 0,019$ .

Менше значення середньоквадратичної помилки (MSE) та вищий коефіцієнт детермінації у моделі LSTM свідчать про її вищу точність. Це по-

яснюється наявністю в архітектурі LSTM спеціальних блоків – «вентилів забування» (*forget gates*), які дозволяють мережі ігнорувати нерелевантний короткостроковий шум у історичних даних та фокусуватися на значущих довгострокових трендах [16]. Це особливо важливо для активів, що демонструють експоненційне зростання, як монета Ахіе у досліджуваному періоді.

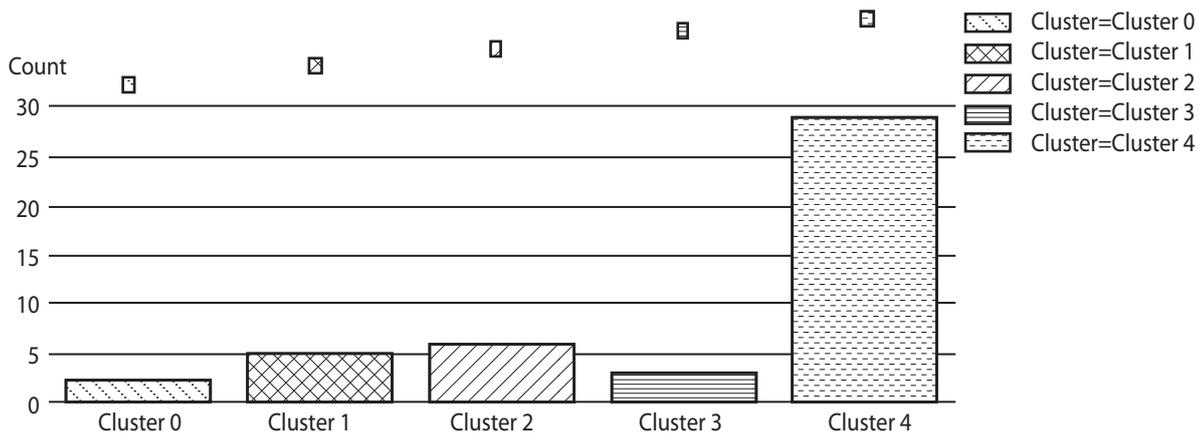
Побудуємо гістограму розподілу елементів (криптовалют) (рис. 9) за кластерами, щоб побачити скільки елементів (криптовалют) в який кластер входять. Аналіз даних рис. 9 дозволяє зробити висновок, що більшість криптовалют ввійшли до 4-го кластера.

Графік відстаней від центроїдів кожного кластера наведено на рис. 10.

Дані рис. 10 дозволяють зробити висновок, що найбільш віддаленим за своїми характеристиками є кластер 3.

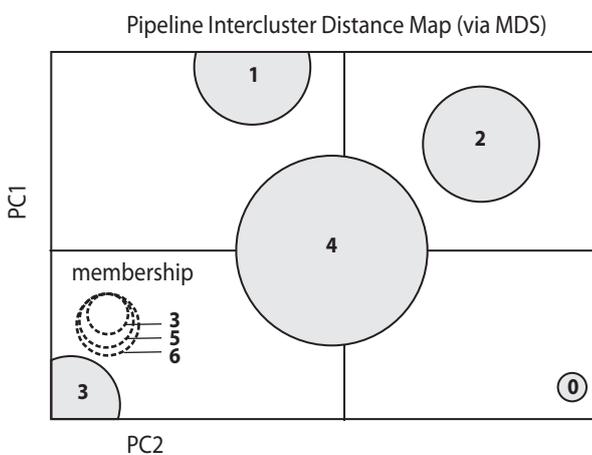
## ВИСНОВКИ

Завершене наукове дослідження успішно представило та практично реалізувало комплексний гібридний підхід до моделювання динаміки



**Рис. 9. Гістограма розподілення елементів за кластерами**

Джерело: побудовано автором на основі [10; 11].



**Рис. 10. Графік відстані до центрів кластерів**

Джерело: побудовано автором на основі [10; 11].

ринку криптовалют, який базується на інтеграції методів кластерного аналізу та нейромережових технологій, що дало змогу підвищити якість управлінських рішень щодо вибору інвестиційної стратегії. Застосування ітеративного методу k-середніх (k-means) забезпечило структурний аналіз багатовимірного простору ознак, дозволивши виділити п'ять стійких кластерів активів за критеріями ризику та прибутковості, причому коректність розбиття підтверджена коефіцієнтом силуету 0,53.

Така попередня селекція дозволила відфільтрувати активи з низьким інвестиційним потенціалом і сконцентрувати подальше моделювання на репрезентантах найбільш привабливих груп, як-от Ахіе (висока прибутковість) та WBTC (низький ризик). Для прогнозування часових рядів вартості цих активів було розроблено та порівняно моделі на базі класичних штучних нейронних мереж (ANN) та мереж довгої короткострокової пам'яті (LSTM), де LSTM продемонструвала значну

перевагу, досягнувши вищого коефіцієнта детермінації ( $R^2 > 0.93$ ) та меншої середньоквадратичної похибки (MSE) на тестових даних. Ця вища точність, особливо помітна в періоди високої волатильності, пояснюється архітектурною особливістю LSTM – наявністю «вентилів забування» (forget gates), які ефективно фільтрують нерелевантний короткостроковий ринковий шум, концентруючись на значущих довгострокових трендах. Практична цінність отриманих результатів полягає в можливості використання розробленого гібридного комплексу як надійного елементу системи підтримки прийняття рішень для інвесторів, забезпечуючи автоматизацію процесу відбору активів та підвищення точності прогнозування їхньої ринкової вартості, що сприяє зниженню ризиків, пов'язаних із суб'єктивною оцінкою.

Подальші наукові дослідження мають бути зосереджені на кількох стратегічно важливих напрямках: поглиблення аналізу системних фінансових ризиків, що виникають через неконтрольоване розповсюдження віртуальних активів, зокрема, стейблкоїнів, чия прив'язка до фіатних валют створює прямий ризик впливу на фінансову стабільність традиційних фінансових систем країнемітентів базової валюти.

Актуальним є вивчення потенціалу технології блокчейн як спільної, відкритої, необмеженої інформаційної інфраструктури у публічному секторі та електронному урядуванні, оскільки її механізми безпеки дозволяють забезпечувати цілісність даних при реєстрації матеріальних та нематеріальних активів (патенти, медичні дані) та безпечному управлінні документами. З технологічної точки зору, необхідно продовжувати дослідження масштабованості шляхом впровадження новітніх архітектур, таких як спрямовані ациклічні графи (DAG) та ієрархічні структури зберігання метаданих, що

є критично важливим для збільшення швидкості обробки транзакцій. Нарешті, оскільки технологія блокчейн не завжди відповідає принципам горизонтальної сумісності, існує нагальна потреба в стандартизації протоколів та подоланні чинного термінологічного дисбалансу та неузгодженості категорій у національній законодавчій базі, що регулює віртуальні активи. ■

#### БІБЛІОГРАФІЯ

1. Дзюндзюк Б. В. Використання технології блокчейн як інформаційної інфраструктури в публічному секторі. *Державне управління: удосконалення та розвиток*. 2023. № 4.  
DOI: <http://doi.org/10.32702/2307-2156.2023.4.9>
2. Костенко О. В., Радутний О. Е. Блокчейн і Метавесвіт: правові аспекти. *Юридичний науковий електронний журнал*. 2022. № 9. С. 499–506.  
DOI: <https://doi.org/10.32782/2524-0374/2022-9/123>
3. Садовий Р. Я. Сутність криптовалюти як економічної категорії в межах технології блокчейн. *Scientific Bulletin of UNFU*. 2024. Vol. 34. № 5. P. 52–61.  
DOI: <https://doi.org/10.36930/40340507>
4. Самсін Р. І. Віртуальні активи: ризик впливу на фінансову стабільність. *Економічна теорія та право*. 2023. № 4 (55). С. 56–72.  
DOI: <https://doi.org/10.31359/2411-5584-2023-55-4-56>
5. Belcastro L., Carbone D., Cosentino C. et al. Enhancing cryptocurrency price forecasting by integrating machine learning with social media and market data. *Algorithms*. 2023. Vol. 16. No. 12. Article 542.  
DOI: <https://doi.org/10.3390/a16120542>
6. Corbet S. Cryptocurrencies as a financial asset: A systematic analysis. *International Review of Financial Analysis*. 2019. Vol. 62. P. 182–199.
7. Hamayel M. J., Owda A. Y. A novel cryptocurrency price prediction model using GRU, LSTM and bi-LSTM machine learning algorithms. *AI*. 2021. Vol. 2, No. 4. P. 477–496.  
DOI: <https://doi.org/10.3390/ai2040030>
8. Hansun S., Wicaksana A., Khaliq A. Q. Multivariate cryptocurrency prediction: Comparative analysis of three recurrent neural networks approaches. *Journal of Big Data*. 2022. Vol. 9. P. 1–15.
9. Hitam N. A., Ismail A. R., Samsudin R., Alkhamash E. H. The effect of kernel functions on cryptocurrency prediction using support vector machines // Proceedings of the International Conference of Reliable Information and Communication Technology. Cham, Switzerland : Springer, 2022. P. 319–332.
10. Kraken: офіційний сайт криптовалютної біржі // Payward, Inc. URL: <https://www.kraken.com/uk>
11. Lai S., Ye C., Zhou H. J. H. Chinese stock trend prediction based on multi-feature learning and model fusion // Proceedings of the 2021 IEEE International Conference on Smart Data Services (SMDS), Chicago, IL, USA, 5–10 September 2021. P. 18–23.
12. Murray K., Rossi A., Carraro D., Visentin A. On forecasting cryptocurrency prices: a comparison of machine learning, deep learning, and ensembles. *Forecasting*. 2023. Vol. 5. No. 1. P. 196–209.  
DOI: <https://doi.org/10.3390/forecast5010010>
13. Ozturk Birim S. An analysis for cryptocurrency price prediction using LSTM, GRU, and the bi-directional implications // Developments in Financial and Economic Fields at the National and Global Scale / M. Cömert, A. E. Şimşek (eds.). Ankara, Türkiye : Gazi Kitabevi, 2022. P. 377–392.
14. Regal A., Morzán J., Fabbri C. et al. Cryptocurrency price projection based on tweets using LSTM. *Ingeniare. Revista Chilena de Ingeniería*. 2019. Vol. 27, No. 4. P. 696–706.  
DOI: [10.4067/s0718-33052019000400696](https://doi.org/10.4067/s0718-33052019000400696)
15. Seabe P. L., Moutsinga C. R. B., Pindza E. Forecasting cryptocurrency prices using LSTM, GRU, and bi-directional LSTM: a deep learning approach. *Fractal and Fractional*. 2023. Vol. 7. No. 2. Article 203.  
DOI: <https://doi.org/10.3390/fractalfract7020203>
16. Singh A., Kumar A., Akhtar Z. Bitcoin price prediction: A deep learning approach // Proceedings of the 2021 8th International Conference on Signal Processing and Integrated Networks (SPIN), Noida, India, 26–27 August 2021. P. 1053–1058.

#### REFERENCES

- Belcastro L., Carbone D., Cosentino C. & et al. (2023). Enhancing cryptocurrency price forecasting by integrating machine learning with social media and market data. *Algorithms*, 12(16), Article 542. <https://doi.org/10.3390/a16120542>
- Corbet S. (2019). Cryptocurrencies as a financial asset: A systematic analysis. *International Review of Financial Analysis*, 62, 182–199.
- Dziundziuk B. V. (2023). Vykorystannia tekhnolohii blokchein yak informatsiinoi infrastruktury v publichnomu sektori [Use of blockchain technology as an information infrastructure in the public sector]. *Derzhavne upravlinnia: udoskonalennia ta rozvytok*, 4. <http://doi.org/10.32702/2307-2156.2023.4.9>
- Hamayel M. J. & Owda A. Y. (2021). A novel cryptocurrency price prediction model using GRU, LSTM and bi LSTM machine learning algorithms. *AI*, 4(2), 477–496. <https://doi.org/10.3390/ai2040030>
- Hansun S., Wicaksana A. & Khaliq A. Q. (2022). Multivariate cryptocurrency prediction: Comparative analysis of three recurrent neural networks approaches. *Journal of Big Data*, 9, 1–15.
- Hitam N. A., Ismail A. R., Samsudin R. & Alkhamash E. H. (2022). The effect of kernel functions on cryptocurrency prediction using support vector

- machines // Proceedings of the International Conference of Reliable Information and Communication Technology. *Springer*, 319–332.
- Kostenko O. V. & Radutnyi O. E. (2022). Blokchein i Metavesvit: pravovi aspekty. [Blockchain and the Metaverse: Legal Aspects]. *Yurydychnyi naukovyi elektronnyi zhurnal*, 9, 499–506. <https://doi.org/10.32782/2524-0374/2022-9/123>
- Lai S., Ye C. & Zhou H. J. H. (2021). Chinese stock trend prediction based on multi feature learning and model fusion // Proceedings of the 2021 IEEE International Conference on Smart Data Services (SMDS). *Chicago, IL, USA*, 18–23.
- Murray K., Rossi A., Carraro D. & Visentin A. (2023). On forecasting cryptocurrency prices: a comparison of machine learning, deep learning, and ensembles. *Forecasting*, 1(5), 196–209. <https://doi.org/10.3390/forecast5010010>
- Ozturk Birim S. (2022). *An analysis for cryptocurrency price prediction using LSTM, GRU, and the bi directional implications // Developments in Financial and Economic Fields at the National and Global Scale*. Gazi Kitabevi.
- Payward, Inc. (2026). Kraken: ofitsiinyi sait kryptovaliutnoi birzhi [Kraken: official website of the cryptocurrency exchange]. *Payward, Inc.* <https://www.kraken.com/uk>
- Regal A., Morzán J., Fabbri C. & et al. (2019). Cryptocurrency price projection based on tweets using LSTM. *Ingeniare. Revista Chilena de Ingeniería*, 4(27), 696–706. <https://doi.org/10.4067/s0718-33052019000400696>
- Sadovyi R. Ya. (2024). Sutnist kryptovaliuty yak ekonomichnoi katehorii v mezhakh tekhnolohii blokchein [The Essence of Cryptocurrency as an Economic Category Within Blockchain Technology]. *Scientific Bulletin of UNFU*, 5(34), 52–61. <https://doi.org/10.36930/40340507>
- Samsin R. I. (2023). Virtualni aktyvy: ryzyk vplyvu na finansovu stabilnist [Virtual Assets: Risk of Impact on Financial Stability]. *Ekonomichna teoriia ta pravo*, 4(55), 56–72. <https://doi.org/10.31359/2411-5584-2023-55-4-56>
- Seabe P. L., Moutsinga C. R. B. & Pindza E. (2023). Forecasting cryptocurrency prices using LSTM, GRU, and bi directional LSTM: a deep learning approach. *Fractal and Fractional*, 2(7), Article 203. <https://doi.org/10.3390/fractalfract7020203>
- Singh A., Kumar A. & Akhtar Z. (2021). Bitcoin price prediction: A deep learning approach // Proceedings of the 2021 8th International Conference on Signal Processing and Integrated Networks (SPIN). *Noida, India*, 1053–1058.

Стаття надійшла до редакції / Received: 05.01.2026 р.

Статтю прийнято до публікації / Accepted: 19.01.2026 р.

Оприлюднено / Published: 25.02.2026 р.