

УДК 004.043

DOI [https://doi.org/10.24144/2616-7700.2026.49\(2\).146-154](https://doi.org/10.24144/2616-7700.2026.49(2).146-154)**Н. І. Бойко<sup>1</sup>, Д. В. Свінцило<sup>2</sup>**<sup>1</sup> Львівський національний університет ветеринарної медицини та біотехнологій імені

Степана Гжицького,

доцент кафедри інформаційних технологій,

кандидат економічних наук

[nataliya.i.boyko@gmail.com](mailto:nataliya.i.boyko@gmail.com)ORCID: <https://orcid.org/0000-0002-6962-9363><sup>2</sup> Національний університет “Львівська політехніка”,

студент кафедри систем штучного інтелекту

[denys.svintsylo.shi.2022@lpnu.ua](mailto:denys.svintsylo.shi.2022@lpnu.ua)ORCID: <https://orcid.org/0009-0008-2381-744X>**НЕЙРОМЕРЕЖЕВИЙ ПРОГНОЗ BITCOIN: АДАПТАЦІЯ ДО ВОЛАТИЛЬНОСТІ**

Стаття присвячена створенню мультимодальної системи прогнозування Bitcoin, яка об'єднує традиційні ринкові показники з аналізом новин через нейромережі LSTM та GRU. Завдяки використанню GDELT та моделі FinBERT авторам вдалося виділити вплив геополітики й фінансів на крипторинки, що підняло точність прогнозів на 15-хвилинних інтервалах з 53,2% до вражаючих 77,8%. Головна особливість підходу — механізм щотижневого адаптивного донавчання, який рятує модель від застарівання, та виявлення 30-хвилинної затримки, з якою макроекономічні новини реально відображаються на ціні. Наукова новизна зосереджена на алгоритмі автоматичного коригування ваг мережі, що дозволяє системі самостійно підтримувати актуальність в умовах хаотичного ринку.

**Ключові слова:** прогнозування криптовалют, Bitcoin, мультимодальний підхід, рекурентні нейронні мережі, сентимент-аналіз, GDELT, адаптивне навчання, LSTM.

**1. Вступ.** Сучасний фінансовий ринок характеризується стрімкою цифровізацією та інтеграцією криптоактивів. Біткоїн, як ключовий актив, демонструє високу волатильність та значну чутливість до інформаційного поля. Традиційні методи аналізу історичних цін часто є малоефективними для децентралізованих ринків, де критичну роль відіграють новини та суспільні настрої. Це зумовлює необхідність розробки мультимодальних систем, здатних одночасно опрацювати кількісні показники та якісні текстові дані.

Метою роботи є розробка та дослідження підходу для фіксації короткострокових коливань ціни криптовалюти через інтеграцію нейромереж LSTM/GRU та сентимент-аналізу новин за допомогою моделі FinBERT. Наукова новизна полягає в удосконаленні архітектури моделей завдяки синергії контекстуального аналізу фінансових новин, рекурентних мереж та градієнтного бустингу, що дозволяє враховувати макроекономічні події в реальному часі. Практичне значення дослідження забезпечується створенням алгоритмічної бази для торгових систем, яка ефективно фільтрує інформаційний шум і підвищує точність сигналів на коротких таймфреймах, долаючи інертність традиційних методів аналізу.

**2. Математична постановка задачі.** Задача прогнозування курсу біткоїна розглядається як аналіз багатовимірних часових рядів, де інформаційний фон (сентимент новин) виступає випереджаючим індикатором цінкових рухів.

Формалізація задачі передбачає визначення мультимодального вектора ознак у момент часу  $t$  [1, 5]:

$$X_t = \{M_t, S_t, T_t\}, \quad (1)$$

де  $M_t$  — вектор ринкових індикаторів (Log-returns, Volatility, SMA deviations);  $S_t$  — вектор ознак настрою (позитивні/негативні оцінки новин, індекси GDELT);  $T_t$  — циклічні часові ознаки.

Прогнозний індикатор  $Y_t$  формується на основі перевищення ціною заданого порогу  $k$  (комісійний бар'єр, прийнятий рівним 0.2%) (2) [3, 4]:

$$Y_t = \begin{cases} 1, & \text{якщо } \frac{C_{t+1}-C_t}{C_t} > k \\ 0, & \text{в іншому випадку} \end{cases}, \quad (2)$$

де  $C_t$  та  $C_{t+1}$  — ціни закриття на поточному та наступному кроці відповідно.

Задача дослідження полягає у знаходженні оператора  $F$  з параметрами  $W$ , що максимізує ймовірність правильної класифікації (3) [3]:

$$\hat{Y}_{t+1} = F(X_t, X_{t-1}, \dots, X_{t-n}; W), \quad (3)$$

де  $n$  — глибина часового вікна (lookback period), яка оптимізується для врахування інерційності ринку.

Для реалізації оператора  $F$  обрано архітектури LSTM та GRU, які ефективно працюють із довгими послідовностями даних, та FinBERT для контекстуального аналізу тексту. Такий підхід трансформує ринковий аналіз у задачу контрольованого навчання (Supervised Learning), орієнтовану на виявлення реальних торгових сигналів [2, 7].

**3. Аналіз літературних джерел.** Дослідники вказують на еволюцію підходів до прогнозування вартості біткоїна: від класичної статистики до складних мультимодальних систем глибокого навчання [6, 8, 11].

Авторами низки робіт [2, 10] підтверджено, що традиційні моделі (зокрема ARIMA) залишаються прозорим базовим інструментом, проте дослідники наголошують на неможливості лінійних моделей адекватно реагувати на раптові ринкові шоки. У науковій спільноті спостерігається перехід до методів машинного (ML) та глибокого навчання (DL). Зокрема, у дослідженні [4] встановлено перевагу архітектур LSTM та Transformer над класичними алгоритмами завдяки їхній здатності вловлювати довгострокові залежності в даних.

Науковці також обґрунтували ефективність використання багатовимірних вхідних даних. Дослідниками [1, 3] доведено, що інтеграція сигналів із Google Trends та соціальних мереж дозволяє суттєво знизити похибки прогнозування порівняно з одновимірними мережами. Проте автори зауважують, що більшість існуючих праць зосереджені на кількісних характеристиках потоку даних, ігноруючи глибокий семантичний контекст новин. На думку дослідників [9], на ринку існує дефіцит систем, які б інтегрували ринкові показники з якісним фінансовим настроєм. Саме на усунення цієї прогалини спрямоване дане дослідження, де авторами пропонується використання спеціалізованої моделі NLP для аналізу контекстуального змісту новин.

**4. Методи та засоби дослідження.** Наукова новизна методу полягає у створенні мультимодальної архітектури, що інтегрує високочастотні котирування (біржа Binance) та семантичні вектори фінансової тональності (платформа GDELT) [3, 5].

Основним елементом є алгоритм структурування даних, що базується на трьох етапах. По-перше, це контекстуальна класифікація, яка розділяє новини за тематиками (крипто, фінанси, геополітика). По-друге, це агрегація сентименту, де масиви тексту перетворюються на числовий сигнал за допомогою індексу тональності  $S_t$  [6, 9]:

$$S_t = \frac{1}{N} \sum_{i=1}^N V2Tone_i, \quad (4)$$

де  $N$  — кількість новин, що потрапили в часове вікно, а  $V2Tone_i$  — значення емоційного забарвлення конкретної публікації.

Для усунення розривів у даних використовується метод Forward Fill. Третім етапом є адаптивна синхронізація індексу з таймфреймами 15, 30 та 60 хвилин.




Рис. 1. а) Гістограму розподілу логарифмічної доходності; б) Діаграма розмаху для коефіцієнта волатильності.

Дослідження також враховує проблему дисбалансу класів та наявність «важких хвостів» у розподілі доходності (аномальні стрибки ціни на 4-12%) [3, 5]. Для вирішення цих задач в архітектуру нейромереж LSTM та GRU впроваджено механізм зважених штрафних функцій. Це дозволяє моделі ідентифікувати зміну настроїв ринку ще до того, як вони повністю відобразяться в котируваннях, що забезпечує значну перевагу над стандартними одномірними моделями. Аналіз логарифмічної доходності та волатильності підтвердив стаціонарність ряду, але виявив «важкі хвости» — аномальні стрибки ціни на 4-12% (Рис. 1(а)–1(б)). Це обґрунтовує використання нейромереж LSTM та GRU, які, завдяки механізмам пам'яті, найкраще адаптуються до таких різких імпульсних змін ринку.

Аналіз кореляційних матриць (Рис. 2(а)–2(б)) виявив високу мультиколінеарність технічних індикаторів та відсутність прямих лінійних зв'язків із ціною. Це підтверджує нелінійність ринку, де вплив новин стає стабільним і помітним лише на довших таймфреймах (від 60 хвилин).

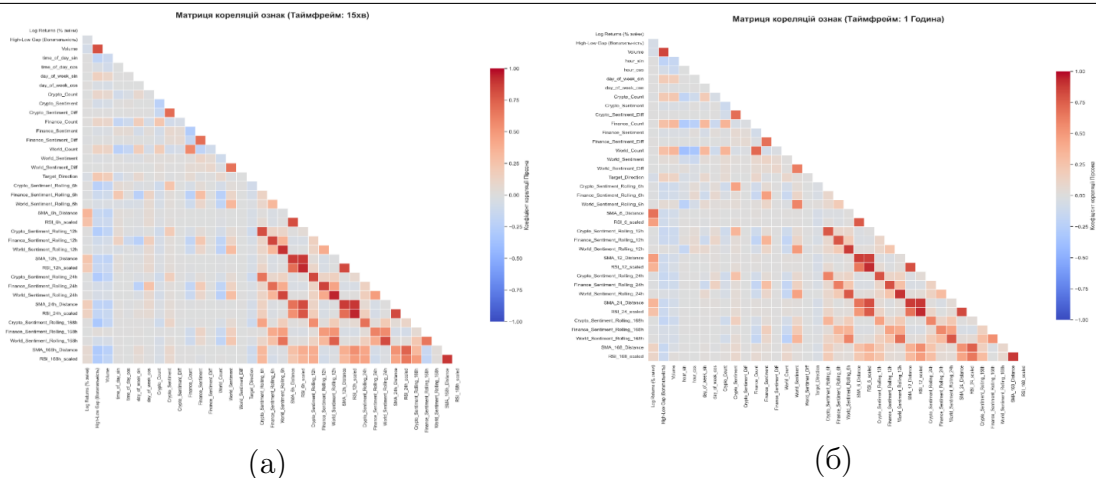


Рис. 2. а) Матриця кореляцій ознак (15хв таймфрейм); б) Матриця кореляцій ознак (60хв таймфрейм).

Метод синтезує дані Vinapse та GDELT, враховуючи внутрішню динаміку ринку та зовнішні макрофактори. Для боротьби зі «старінням» моделі впроваджено щотижневе адаптивне донавчання з низьким *learning rate* та блоком автоматичного контролю: ваги оновлюються лише при зростанні точності. Експерименти підтвердили перевагу такого динамічного підходу над статичними моделями (Табл. 1).

Таблиця 1.

Порівняння моделей без донавчання та з донавчанням

N тижня	Статична модель		Модель з щотижневим донавчанням	
	Точність (%)	Кількість сигналів	Точність	Кількість сигналів
1	100	2	100	2
2	66.7	3	70	20
3	0	0	100	5
4	0	0	75	16
5	51.2	168	51.5	330
6	52.2	228	58.9	90
7	46.9	614	46.6	350
8	54.6	335	0	0
9	62.7	51	0	0
10	60	150	62.5	72
11	51.7	29	83.3	6
12	53.2	94	57.7	

Поєднання методів обробки «важких хвостів» та рекурентних нейромереж зробило систему стійкою до ринкового хаосу. Експерименти довели критичну роль зовнішніх факторів: мультимодальний підхід підвищив точність впевнених сигналів з 49,39% (рівень випадковості) до 51,96% (Табл. 2). Це підтверджує, що семантичний аналіз новин є необхідним для подолання порогу ринкової ефективності.

Таблиця 2.

## Результати тестування моделі ARIMAX

N	Метрика	Тільки історичні дані	Історичні дані + сентимент	Різниця
1	RMSE (\$)	559.71	560.58	+0.87 (погіршення)
2	General DA (%)	49.15%	50.28%	+1.13%
3	High Conf. DA (%)	49.39%	51.96%	+2.57%
4	Кількість угод	330	306	-24

Отримані результати доводять, що навіть лінійні статистичні моделі демонструють якісне покращення при інтеграції текстових даних, що обґрунтовує подальше використання глибших нейронних архітектур (Рис. 3).




Рис. 3. (а) Графік передбачень мультимодальної моделі ARIMAX; (б) Графік передбачень мультимодальної моделі XGboost.

Аналіз ARIMAX (Рис. 3(а)) виявив структурну затримку в один крок, яку не вдалося усунути навіть попри врахування сентименту через лінійну природу моделі. Для подолання цього ефекту та пошуку нелінійних патернів застосовано XGBoost із лаговими ознаками (1–6 годин). Особливістю етапу стала імітація реальної торгової стратегії з фільтрацією сигналів за порогом впевненості Табл. 3 та на Рис. 3(б).

Таблиця 3.

## Результати тестування моделі XGBoost

N	Метрика	Тільки історичні дані	Історичні дані + сентимент	Різниця
1	RMSE (\$)	564.57	565.03	+0.46 (погіршення)
2	General DA (%)	52.28%	52.05%	-0.23%
3	High Conf. DA (%)	52.35%	53.33%	+0.98%
4	Кількість угод	149	120	-29

Використання XGBoost дозволило виявити нелінійні патерни та підвищити точність впевнених прогнозів до 53,33%. Сентимент-аналіз спрацював як фільтр, відсікаючи «шумові» сигнали та скорочуючи кількість угод, що підвищило якість торгової логіки.

На етапі нейромережевого моделювання (оптимізованого через Optuna та MFlow) перехід до бінарної класифікації дозволив досягти таких результатів (Рис. 4):

1. 15 хв: точність 77,8% на базі крипто-сентименту (поріг 0,65).
2. 30 хв: точність 63,6% при інтеграції всіх типів новин.
3. 60 хв: точність 56,5% на основі крипто-новин (поріг 0,7).

Експериментально доведено: на коротких інтервалах вирішальним є вузькоспеціалізований сентимент, а на довгих — комплексний макроекономічний фон.

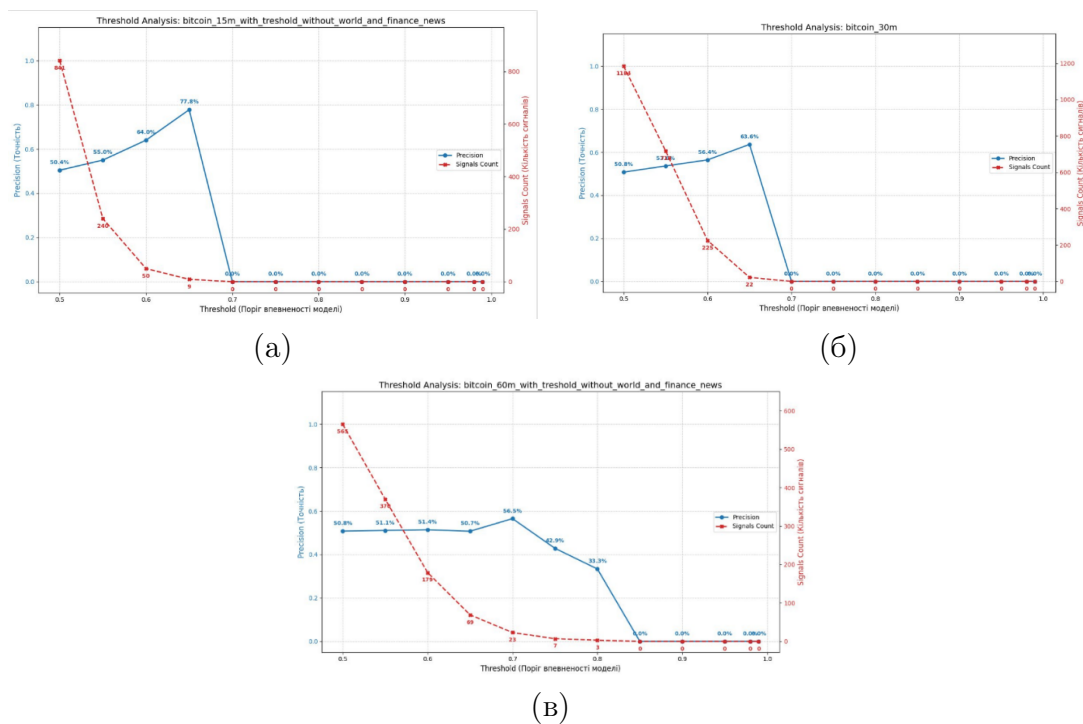


Рис. 4. Співвідношення High-Confidence Precision до кількості загальних сигналів: а) для датасету з таймфреймом 15 хвилин; б) для датасету з таймфреймом 30 хвилин; в) для датасету з таймфреймом 60 хвилин.

Результати в Табл. 4 підтверджують, що перехід до класифікації та використання динамічних порогів впевненості дозволяє генерувати точні торгові сигнали. Найвищу ефективність виявлено на 15-хвилинному таймфреймі, де крипто-сентимент виступає ключовим випереджаючим індикатором.

Обрана сукупність методів формує замкнений цикл аналітичної обробки — від збору сирих сигналів до генерації прецизійних прогнозів. Поєднання рекурентних мереж із баєсівською оптимізацією дозволило структурувати хаотичні інформаційні потоки, а диференціація сентименту за категоріями допомогла ідентифікувати латентні закономірності, недоступні класичним моделям.

Таблиця 4.

## Порівняння результатів усіх моделей

Часовий таймфрейм з певним типом новин	Precision (%)	Кількість сигналів
15хв (крипто новини)	77.8	9
15хв (крипто+фінанс новини)	70	10
15хв (крипто+фінанс+світові новини)	59.3	27
30хв (крипто новини)	49.6	895
30хв (крипто+фінанс новини)	51.5	782
30хв (крипто+фінанс+світові новини)	63.6	22
60хв (крипто новини)	56.5	23
60хв (крипто+фінанс новини)	56.6	106
60хв (крипто+фінанс+світові новини)	55.4	439

**5. Висновки та перспективи подальших досліджень.** У результаті апробації мультимодальної системи встановлено, що інтеграція семантичного аналізу дозволяє подолати «поріг випадковості», підвищивши точність прогнозів із 53,2% до 77,8% на 15-хвилинному інтервалі. Дослідження виявило ефект гетерогенного запізнення, де ринок реагує на крипто-новини майже миттєво, тоді як макроекономічні події інтегруються в ціну з інертністю близько 30 хвилин. Завдяки впровадженню зважених функцій втрат у рекурентні мережі LSTM та GRU вдалося адаптувати систему до аномальних стрибків ціни («важких хвостів»), які зазвичай ігноруються класичною статистикою. Крім того, реалізований метод інкрементального донавчання на мікро-сегментах даних ефективно вирішує проблему «застарівання» моделі, підтримуючи актуальність її ваг у реальному часі.

Перспективи подальших досліджень зосереджені на переході до гібридних архітектур на основі Transformers та залученні On-chain метрик. Наступним кроком стане впровадження агентів підкріпленого навчання (Reinforcement Learning) для динамічної оптимізації портфеля в умовах високої ринкової волатильності.

---

### Конфлікт інтересів

---

Автори заявляють, що не мають конфлікту інтересів щодо даного дослідження, включаючи фінансовий, особистий, авторський або будь-який інший, який міг би вплинути на дослідження, а також на результати, представлені в даній статті.

---

### Фінансування

---

Дослідження було проведено без фінансової підтримки.

---

### Доступність даних

---

Оригінальні дані, представлені в дослідженні, відкрито доступні для академічних досліджень у репозиторії Github за адресою:  
<https://github.com/DEN228228/crypto-prediction>

---

### Використання штучного інтелекту

---

Автори підтверджують, що при створенні даної роботи вони не використовували технології штучного інтелекту.

---

### Внесок авторів

---

Н. І. Бойко: концептуалізація, курація даних, формальний аналіз, Д. В. Свінцило: формальний аналіз, методологія, написання — оригінальний проект.

Авторські права ©



(2026). Бойко Н. І., Свінцило Д. В. Ця робота ліцензується відповідно до Creative Commons Attribution 4.0 International License.

---

### Список використаної літератури

1. Akyildirim, E., Corbet, S., Katsiampa, P., Kellard, N., & Sensoy, A. (2021). Prediction of cryptocurrency returns using machine learning. *Finance Research Letters*, 38, 101438. <https://doi.org/10.1016/j.frl.2020.101438>
2. Chen, C., Ma, Y., Wang, X., & He, L. (2020). Forecasting Bitcoin price with deep learning-based approaches. *Journal of Computational Finance*, 24(3), 1–20. <https://doi.org/10.21314/JCF.2020.390>
3. Greaves, A. S., & Au, B. (2019). Using machine learning algorithms to predict Bitcoin price movements. *Computational Economics*, 53(4), 1003–1021. <https://doi.org/10.1007/s10614-018-9844-y>
4. Kim, Y., Kim, H., & Lee, J. (2021). Transformer-based models for cryptocurrency price prediction: A comparative analysis. *Expert Systems with Applications*, 174, 114768. <https://doi.org/10.1016/j.eswa.2021.114768>
5. Shah, D., Isah, H., & Zulkernine, F. (2019). Stock market analysis: A review and taxonomy of prediction techniques. *International Journal of Financial Studies*, 7(2), 26. <https://doi.org/10.3390/ijfs7020026>
6. Zhang, X., Liu, Y., & Luo, X. (2022). Enhancing cryptocurrency price prediction using hybrid deep learning models. *Journal of Financial Data Science*, 4(2), 45–61. <https://doi.org/10.3905/jfds.2021.1.077>
7. Htay, H. S., & et al. (2025). Enhancing Bitcoin price prediction with deep learning: Integrating social media sentiment and historical data. *Applied Sciences*, 15(3), 1554. <https://doi.org/10.3390/app15031554>
8. Huang, A. H., Wang, H., & Yang, Y. (2022). FinBERT: A large language model for extracting information from financial text. *SSRN*. [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3910214](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3910214)
9. Mao, Y., & et al. (2024). Sentiment analysis methods, applications, and challenges: A systematic literature review. *Journal of King Saud University – Computer and Information Sciences*, 36(4), 102048. <https://doi.org/10.1016/j.jksuci.2024.102048>
10. Scanlon, B., & et al. (2025). Optimizing Bitcoin price prediction: Multivariate LSTM triumphs.

**Boyko N. I., Svinchylo D. V.** Neural Price Forecasting for Bitcoin: Adapting to Volatility.

The article focuses on the development of a multimodal Bitcoin forecasting system that integrates traditional market metrics with news analysis using LSTM and GRU neural networks. By leveraging GDELT and the FinBERT model, the authors successfully isolated the impact of geopolitical and financial news on the crypto market, boosting 15-minute timeframe prediction accuracy from 53.2% to an impressive 77.8%. A key feature of this approach is the weekly adaptive retraining mechanism, which prevents model degradation, alongside the discovery of a 30-minute time lag for macroeconomic news to be fully reflected in price action. The scientific novelty centers on an automated weight adjustment algorithm that enables the system to maintain relevance within a chaotic market environment.

**Keywords:** cryptocurrency forecasting, Bitcoin, multimodal approach, recurrent neural networks, sentiment analysis, GDELT, adaptive learning, LSTM.

Отримано: 25.03.2026

Прийнято: 08.04.2026

Опубліковано: 30.04.2026