

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
ДЕРЖАВНИЙ УНІВЕРСИТЕТ ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНИХ  
ТЕХНОЛОГІЙ

Кваліфікаційна наукова праця  
на правах рукопису

**ЦАПРО ІГОР ВІКТОРОВИЧ**

УДК 004.41:004.85:519.87:336.74

**ДИСЕРТАЦІЯ**

**МЕТОД АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ДИНАМІКИ РИНКУ  
КРИПТОВАЛЮТ НА ОСНОВІ МЕХАНІСТИЧНОГО ПІДХОДУ ТА  
МАШИННОГО НАВЧАННЯ**

Спеціальність 121 «Інженерія програмного забезпечення»

Подається на здобуття наукового ступеня  
доктора філософії

Дисертація містить результати власних досліджень. Використання ідей,  
результатів і текстів інших авторів мають посилання на відповідне джерело

Ігор ЦАПРО

Науковий керівник:  
ЗОЛОТУХІНА Оксана Анатоліївна,  
кандидат технічних наук, доцент

Київ – 2026

## АНОТАЦІЯ

**Цапро І. В.** Метод аналізу та прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 121 «Інженерія програмного забезпечення» – Державний університет інформаційно-комунікаційних технологій, Київ, 2026.

У дисертаційній роботі вирішується актуальна наукова задача розробки методу аналізу та прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання, що зумовлено необхідністю створення більш інформативних, адаптивних та стійких систем підтримки прийняття рішень, здатних працювати в умовах високої волатильності, гетероскедастичності та структурної складності фінансових часових рядів, забезпечуючи пояснюваність рішень, які базуються на фундаментальному ринковому механізмі: взаємодії попиту та пропозиції.

У дисертаційній роботі нові наукові результати і висновки отримані на основі механістичного підходу, методах аналізу часових рядів, машинного навчання для класифікації часових рядів, статистичних методів, методи ретроспективного тестування, теорії прийняття рішень, алгоритмів, методи програмної інженерії. Вірогідність наукових результатів, висновків і рекомендацій, викладених у дисертаційній роботі, обґрунтовано використанням математичного апарату та моделювання на ЕОМ.

У процесі теоретичних досліджень і моделювання у дисертаційній роботі отримані наступні наукові результати:

1) удосконалено метод механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці, що дозволило формалізовано оцінювати взаємодію попиту та пропозиції в умовах високої волатильності та нестационарності ринку;

2) вперше розроблено показник поглинання імпульсу (Momentum Absorption Score, MAS), який ґрунтується на статистичному виявленні зон низької волатильності при аномально високих торгових обсягах за допомогою z-оцінок та процентильного аналізу і є складовою удосконаленого методу механістичного аналізу динаміки криптовалютних активів, що дозволило ідентифікувати приховані фази накопичення та розподілу активів, які передують значним ціновим рухам;

3) удосконалено метод прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу (механістичної ковзної та показника MAS) із застосуванням ансамблевого машинного навчання та класифікації прибутковості подій за методом потрібних бар'єрів, що дозволило підвищити точність ідентифікації інформативних сигналів та мінімізувати вплив ринкового шуму;

4) дістали подальшого розвитку архітектурні рішення реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи за рахунок впровадження модульної монолітної структури з розділеними контурами навчання та інференсу, що дозволило забезпечити ізоляцію ресурсоємних процесів та спростити інтеграцію механістичних показників.

Практичне значення одержаних результатів:

1) результати дослідження можуть бути використані при побудові інтелектуальних систем підтримки прийняття рішень у фінансовому секторі для забезпечення високоточного аналізу та прогнозування динаміки криптовалютного ринку в умовах високої волатильності та нестационарності часових рядів;

2) використання технологій ЛТ-компіляції та паралелізації обчислень у програмній реалізації розроблених моделей дозволило досягти суттєвого підвищення обчислювальної продуктивності, що виражається у скороченні часу розрахунку складних показників з 2,0 до 0,6 секунди;

3) наукові положення, теоретичні та експериментальні результати, отримані в дисертаційній роботі, впроваджені у практичну діяльність ФОП Новіцька А. В. (акт від 01.05.2026 р.) та дозволили підвищити обґрунтованість бізнес-рішень у комунікації з інвесторами, партнерами по біржі та розробки токеноміки для

майбутніх клієнтів, зменшити відсоток хибно позитивних оцінок цінової динаміки токєну компанії у наступні 3, 6 та 12 місяців на 11% та скоротити час на аналіз ринкових даних на 40% завдяки впровадженню програмно-технологічних засобів реалізації інтелектуальних систем аналізу даних;

4) результати дослідження використовуються у науково-дослідній роботі Державного університету інформаційно-комунікаційних технологій (№ держ. реєстрації 0121U107501 та 0126U000001), а також у навчальному процесі при викладанні дисциплін: «Технології Big Data» та «Програмування».

Практична цінність роботи підтверджена актом впровадження в ФОП Новіцька Анна Валеріївна (акт від 01.05.2026 р.), а також відображена у звітах про науково-дослідну роботу Державного університету інформаційно-комунікаційних технологій: «Забезпечення функціональної стійкості інформаційних систем підприємства в умовах впливу дестабілізуючих факторів із застосуванням нейронних мереж» (№ держ. реєстрації 0121U107501, термін виконання 2021-2025, ДУІКТ, м. Київ) (авторський внесок полягає у розробці методу машинного навчання для відсіювання хибно позитивних прогнозів); «Методи, моделі та програмні засоби інтелектуальної обробки даних фінансових ринків» (№ держ. реєстрації 0126U000001, термін виконання 01.2026-01.2029, ДУІКТ, м. Київ) (авторський внесок полягає в аналізі динаміки цінових тенденцій фінансових ринків з використанням машинного навчання).

**Ключові слова:** криптовалюта; криптоактиви; ринок криптовалют; торгові обсяги; статистичний аналіз; технічний аналіз; ковзна середня; механістичний підхід; механістичні показники; показник поглинання імпульсу (Momentum Absorption Score, MAS); прогнозування; дані; машинне навчання; ансамблеве машинне навчання; архітектура програмного забезпечення; програмне забезпечення; модульна монолітна структура; інтелектуальна система.



## ABSTRACT

**Tsapro I. V.** Method of analysis and forecasting of cryptocurrency market dynamics based on a mechanistic approach and machine learning. – Qualifying scientific work on the rights of the manuscript.

Dissertation for the degree of Doctor of Philosophy in specialty 121 "Software Engineering" – State University of Information and Communication Technologies, Kyiv, 2026.

The dissertation addresses the urgent scientific problem of developing a method of analysis and forecasting of cryptocurrency market dynamics based on a mechanistic approach and machine learning, which is due to the need to create more informative, adaptive and stable decision support systems capable of working in conditions of high volatility, heteroscedasticity and structural complexity of financial time series, ensuring the explainability of decisions based on the fundamental market mechanism: the interaction of demand and supply.

In the dissertation, new scientific results and conclusions are obtained on the basis of a mechanistic approach, methods of time series analysis, machine learning for time series classification, statistical methods, methods of retrospective testing, decision theory, algorithms, methods of software engineering. The reliability of the scientific results, conclusions and recommendations presented in the dissertation is substantiated by the use of mathematical framework and computer modeling.

The following scientific results have been obtained in the dissertation:

1. The method of mechanistic analysis of the dynamics of cryptocurrency assets was improved by integrating data on separate volumes of market purchases, sales and their absolute difference, which allowed for a formal assessment of the interaction of supply and demand in conditions of high volatility and market non-stationarity.

2. For the first time, the Momentum Absorption Score (MAS) was developed, which is based on the statistical detection of low volatility zones with abnormally high trading volumes using z-scores and percentile analysis and is a component of an improved method of mechanistic analysis of the dynamics of cryptocurrency assets, which made it possible to

identify hidden phases of asset accumulation and distribution that precede significant price movements.

3. The method of forecasting the dynamics of the cryptocurrency market has been improved by introducing a stage of intelligent filtering of trading signals formed on the basis of mechanistic analysis indicators (mechanistic moving average and MAS) using ensemble machine learning and classification of event profitability using the triple barriers method, which allowed to increase the accuracy of identifying informative signals and minimize the impact of market noise.

4. Architectural solutions for implementing methods for analyzing and forecasting cryptocurrency market dynamics as part of a single intelligent system were further developed through the implementation of a modular monolithic structure with separate learning and inference modules, which allowed for the isolation of resource-intensive processes and simplified the integration of mechanistic indicators.

Practical significance of the results obtained:

1. The results of the study can be used in building intelligent decision-making support systems in the financial sector to ensure high-precision analysis and forecasting of the dynamics of the cryptocurrency market in conditions of high volatility and non-stationarity of time series.

2. The use of JIT compilation and parallelization of calculations in the software implementation of the developed models allowed achieving a significant increase in computational efficiency, which is expressed in a reduction in the time for calculating complex indicators from 2.0 to 0.6 seconds.

3. Scientific provisions, theoretical and experimental results obtained in the dissertation work, implemented in the practical activities of the individual entrepreneur Novitska A. V. (act dated 01.05.2026), which allowed to increase the validity of business decisions in communication with investors, exchange partners and the development of tokenomics for future clients, reduce the percentage of false positive estimates of the price dynamics of the company's token in the next 3, 6 and 12 months by 11% and reduce the time for analyzing market data by 40% due to the implementation of software and technological means for implementing intelligent data analysis systems;

4. The results of the study are used in the scientific and research work of the State University of Information and Communication Technologies (state registration numbers 0121U107501 and 0126U000001), as well as in the educational process when teaching the disciplines: "Big Data Technologies" and "Programming".

The practical value of the work is confirmed by the act of implementation in the individual entrepreneur Novitska Anna Valeriivna (act dated 01.05.2026), and is also reflected in the reports on the scientific and research work of the State University of Information and Communication Technologies: "Ensuring the functional stability of enterprise information systems under the influence of destabilizing factors with the application using neural networks" (state registration number 0121U107501, implementation period 2021-2025, DUICT, Kyiv) (the author's contribution consists in developing a machine learning method for screening out false positive forecasts); "Methods, models and software tools for intelligent data processing of financial markets" (state registration number 0126U000001, implementation period 01.2026-01.2029, DUICT, Kyiv) (the author's contribution consists in analyzing the dynamics of price trends in financial markets using machine learning).

**Keywords:** cryptocurrency; cryptoassets; cryptocurrency market; trading volumes; statistical analysis; technical analysis; moving average; mechanistic approach; mechanistic indicators; Momentum Absorption Score (MAS); forecasting; data; machine learning; ensemble machine learning; software architecture; software; modular monolithic structure; intelligent system.

## СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

*Наукові праці, в яких опубліковані основні наукові результати дисертації:*

1. Цапро І.В. Адаптація механістичного підходу до аналізу ринку криптовалют. Зв'язок, 2023, № 1 (161), с. 47-51. DOI: 10.31673/2412-9070.2023.014647.
2. Tsapro, I. A comparative study between price-driven and mechanistic moving averages using causal analysis on Bitcoin historical data. Radioelectronic and Computer Systems, 2025, vol 2025, no. 1, pp. 44-57. DOI: 10.32620/reks.2025.1.03.
3. Цапро І. В., Золотухіна О. А. Вдосконалення механістичного підходу з використанням даних ринкових обсягів біткоїна. Зв'язок, 2025, № 3 (175), с. 87-94. DOI: 10.31673/2412-9070.2025.026142.
4. Цапро І. В. Застосування машинного навчання в задачі відсіювання неефективних торгових сигналів згенерованих показниками механістичного підходу. Зв'язок, № 5 (177), 2025, с. 79-86. DOI: 10.31673/2412-9070.2025.051067.
5. Цапро І. В., Золотухіна О. А. Програмна реалізація показника поглинання імпульсу як статистичного інструменту на ринку біткоїна. Зв'язок, 2026, № 3. DOI: 10.31673/2412-9070.2026.318113.

*Наукові праці, які засвідчують апробацію матеріалів дисертації:*

1. Цапро І.В., Золотухіна О.А. Актуальність механістичного підходу та машинного навчання для аналізу ринку криптовалют. Збірник тез. Міжнародна науково-практична конференція «Сучасні аспекти діджиталізації та інформатизації в програмній та комп'ютерній інженерії», 1 – 3 червня 2023 року, ДУІКТ, м. Київ, с. 80-81. URL: [https://duikt.edu.ua/uploads/n\\_11337\\_64054605.pdf](https://duikt.edu.ua/uploads/n_11337_64054605.pdf).
2. Цапро І.В., Золотухіна О.А. Дизайн архітектури програмного забезпечення виявлення аномалій для підтримки ухвалення рішень на ринку криптовалют. Збірник тез. Всеукраїнська науково-технічна конференція «Застосування програмного забезпечення в інформаційно-комунікаційних технологіях», 24 квітня 2024 року, ДУІКТ, м. Київ, с. 96-98. URL: [https://duikt.edu.ua/uploads/p\\_2661\\_45497999.pdf](https://duikt.edu.ua/uploads/p_2661_45497999.pdf).

3. Цапро І.В., Золотухіна О.А. Порівняння методів аналізу торгових обсягів у середовищі python. Збірник тез. Всеукраїнська, науково-практична конференція молодих учених та студентів «Інформаційні технології в освіті, техніці та промисловості», 10 жовтня 2024 року, ІФНТУНГ, м. Івано-Франківськ, с. 169-171. URL: [https://drive.google.com/file/d/1XrD-obOLO\\_MBz3DuotBYS4S7fKqycmFS/view](https://drive.google.com/file/d/1XrD-obOLO_MBz3DuotBYS4S7fKqycmFS/view).

4. Цапро І.В., Золотухіна О.А. Зменшення часу перетренування моделей машинного навчання. Збірник тез. II Всеукраїнська науково-технічна конференція «Технологічні горизонти: дослідження та застосування інформаційних технологій для технологічного прогресу України і світу», 18 листопада 2024 року, ДУІКТ, м. Київ, с. 77-79. URL: [https://duikt.edu.ua/uploads/p\\_2661\\_83654085.pdf](https://duikt.edu.ua/uploads/p_2661_83654085.pdf).

5. Цапро І.В., Золотухіна О.А. Оцінка ефективності алгоритмічних торгових стратегій у розрізі висхідного та спадного трендів. Збірник тез. Всеукраїнська науково-технічна конференція «Застосування програмного забезпечення в ІКТ», 24 квітня 2025 року, ДУІКТ, м. Київ, с. 554-556. URL: [https://duikt.edu.ua/uploads/p\\_2779\\_56719466.pdf](https://duikt.edu.ua/uploads/p_2779_56719466.pdf).

6. Цапро І.В., Золотухіна О.А. Застосування алгоритмів машинного навчання в прогнозуванні напрямку руху цін криптоактивів. Збірник тез. Всеукраїнська науково-технічна конференція «Виклики та рішення в програмній інженерії», 26 листопада 2025 року, ДУІКТ, м. Київ, с. 355-357. URL: [https://duikt.edu.ua/uploads/p\\_2779\\_29705833.pdf](https://duikt.edu.ua/uploads/p_2779_29705833.pdf).

7. Цапро І.В., Золотухіна О.А. Оптимізація обчислень показника поглинання імпульсу методами динамічної компіляції та кешування. Збірник тез. VII Всеукраїнська науково-технічна конференція «Застосування програмного забезпечення в інформаційно-комунікаційних технологіях», 23 квітня 2026 року, ДУІКТ, м. Київ, с. 361-363, URL: [https://duikt.edu.ua/uploads/p\\_3086\\_61927919.pdf](https://duikt.edu.ua/uploads/p_3086_61927919.pdf).

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ	14
ВСТУП	15
РОЗДІЛ 1. КОНЦЕПТУАЛЬНІ ЗАСАДИ ТА ОГЛЯД ДОСЛІДЖЕНЬ РИНКУ КРИПТОВАЛЮТ	23
1.1 Ринок криптовалют та його особливості	23
1.2 Методи технічного аналізу в задачах прогнозування динаміки криптовалютного ринку	26
1.2.1 Технічний аналіз та його складові	26
1.2.2 Недоліки технічного аналізу	29
1.3 Методи аналізу торгових обсягів в задачах прогнозування динаміки криптовалютного ринку	35
1.3.1 Зв'язок торгових обсягів та ціни	35
1.3.2 Методи аналізу та прогнозування динаміки ринку криптовалют на основі торгового обсягу	37
1.3.3 Ринкові та лімітні обсяги	40
1.4 Основні напрямки та завдання дисертаційного дослідження	49
Висновки до розділу 1	52
РОЗДІЛ 2. МЕХАНІСТИЧНИЙ ПІДХІД ТА МАШИННЕ НАВЧАННЯ В ЗАДАЧАХ ПРОГНОЗУВАННЯ РИНКОВИХ ТЕНДЕНЦІЙ	53
2.1 Еконофізика в економіці та фінансах	53
2.2 Місце та роль механістичного підходу в задачах прогнозування ринкових тенденцій	55
2.3 Машинне навчання в задачах прогнозування ринкових тенденцій	58
2.3.1 Основні поняття та алгоритми машинного навчання	58

	11
2.3.2 Застосування машинного навчання в задачах прогнозування ринкових тенденцій	66
2.4 Причинно-наслідковий аналіз	72
Висновки до розділу 2	73
РОЗДІЛ 3. РОЗРОБКА МЕТОДІВ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ДИНАМІКИ РИНКУ КРИПТОВАЛЮТ	75
3.1 Удосконалення методу механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці	75
3.2 Розробка показника поглинання імпульсу (Momentum Absorption Score, MAS)	80
3.3 Розробка удосконаленого методу прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу	88
3.3.1 Визначення цільових змінних, даних та моделей	88
3.3.2 Визначення методу машинного навчання для інтелектуальної фільтрації торгових сигналів	92
3.4 Розробка архітектурних рішень реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи	98
3.4.1 Алгоритм реалізації методу машинного навчання для інтелектуальної фільтрації торгових сигналів	98
3.4.2 Архітектура програмної реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи	102
Висновки до розділу 3	109
РОЗДІЛ 4. РЕЗУЛЬТАТИ ДОСЛІДЖЕНЬ МЕТОДІВ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ДИНАМІКИ РИНКУ КРИПТОВАЛЮТ	111
4.1 Оглядове порівняння методів аналізу торгових обсягів	111

	12
4.2 Адаптація механістичного підходу до аналізу ринку криптовалют	112
4.3 Порівняльне дослідження цінової та механістичної ковзних середніх з використанням причинно-наслідкового аналізу на історичних даних Біткоїна	115
4.3.1 Дані та ретроспективні тести	115
4.3.2 Тенденції прибутків та коефіцієнтів виграшу	116
4.3.3 Аналіз розподілів	120
4.3.4 Напрямок тренду та прибутки	122
4.3.5 Причинно-наслідковий ефект використання MSMA на прибутки	123
4.3.6 Причинно-наслідковий ефект напрямку тренду на прибутки для MSMA	124
4.4 Експериментальна валідація та оцінювання точності удосконаленого методу механістичного аналізу динаміки криптовалютних активів	125
4.4.1 Дані та ретроспективні тести	125
4.4.2 Результати ретроспективних тестувань	126
4.5 Експериментальна валідація та оцінювання точності показника поглинання імпульсу	136
4.5.1 Дані та ретроспективні тести	136
4.5.2 Результати ретроспективних тестувань	140
4.6 Експериментальна валідація та оцінювання точності удосконаленого методу прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу	150
4.6.1 Дані та конфігурація моделювання	150
4.6.2 Результати валідації моделей машинного навчання	151
4.7 Оцінювання архітектурної стійкості та ізоляції модулів інтелектуальної системи	160
Висновки до розділу 4	163



	13
ВИСНОВКИ	166
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	169
ДОДАТОК А Топ 10 комбінацій за Sharpe Ratio для довгих та коротких позицій	185
ДОДАТОК Б Екранні форми програмної реалізації методу аналізу та прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання	187
ДОДАТОК В NumPy імплементація механістичної ковзної та показника поглинання імпульсу	189
ДОДАТОК Г Акти впровадження наукових досліджень дисертаційної роботи	191
ДОДАТОК Д Список опублікованих праць за темою дисертації	193

## ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

BTC	– Біткоїн
TP	– Тейк-профіт, або ж ціль фіксації позиції в прибуток
SL	– Стоп-лос, або ж ціль фіксації позиції в збиток
MA	– Ковзна середня (узагальнено)
SMA	– Проста ковзна середня
EMA	– Експоненційна ковзна середня
MACD	– Індикація збіжності/розбіжності ковзних середніх
RSI	– Індекс відносної сили
HHT	– Перетворення Гільберта-Хуана
VWAP	– Середньозважена за обсягом ціна
MSMA	– Механістична проста ковзна середня
VD	– Дельта обсягів покупок та продажів
VB	– Співвідношення обсягів покупок до сумарних обсягів
VDC	– Кумулятивна дельта обсягів покупок та продажів
GMI	– Генералізований показник імпульсу
MAS	– Показник поглинання імпульсу
ML	– Машинне навчання
AI	– Штучний інтелект
ANN	– Штучна нейронна мережа
CNN	– Згорткова нейронна мережа
RNN	– Рекурентна нейронна мережа
AP	– Середня точність, обчислена там, де зростає повнота
TBM	– Метод потрібних бар'єрів
MCDM	– Прийняття рішень на основі багатокритеріального аналізу
API	– Прикладний програмний інтерфейс
JIT	– Just-in-time compilation, або компіляція «на льоту»
UI	– Інтерфейс користувача

## ВСТУП

**Актуальність.** Стрімкий розвиток криптовалют, сформував новий клас ринків, який характеризується високою волатильністю та цілодобовим режимом функціонування [1]. На відміну від традиційних фінансових ринків, криптовалютний ринок працює без централізованого механізму відкриття та закриття торгових сесій, має значно вищу частоту структурних змін, а також демонструє більш виражені нелінійні залежності між торговою активністю та рухом ціни. Дослідження останніх років вказують на те, що криптовалютні ринки залишаються одним із найскладніших середовищ для побудови стійких прогнозних моделей через високу шумність, нестабільність розподілів та часті зсуви режимів [6]. Однак, ринки криптовалют це підмножина ринків капіталу, де більша кількість та різноманітність учасників, а торгові обсяги, загалом, можуть бути прийнятно точно відслідковані та проаналізовані, на відміну від ринків валют, металів та інших подібних.

Традиційні методи технічного аналізу здебільшого базуються на аналізі лише цінових часових рядів, таких як ціна відкриття, максимум, мінімум та ціна закриття [9]. Проте ціна є лише фінальним результатом складного процесу взаємодії покупців і продавців. Вона відображає вже реалізований баланс попиту та пропозиції, але не розкриває внутрішні механізми формування цього балансу. Унаслідок цього такі моделі часто демонструють низьку стійкість у періоди різких змін ліквідності, сплесків торгової активності або домінування великих учасників ринку [24].

У цьому контексті особливої актуальності набуває застосування механістичного підходу до аналізу фінансових часових рядів. Його основна ідея полягає у переході від спостереження лише за наслідком ринкової взаємодії (ціною) до аналізу безпосередньо механізму генерації ринкових даних. Такий підхід дозволяє наблизитися до реального механізму формування ціни та виявляти фази накопичення позицій, поглинання ринкового імпульсу, аномальні сплески активності та локальні дисбаланси попиту і пропозиції, які часто передують значним ринковим рухам. Науковці M. Ausloos, K. Ivanova та інші [59] зробили суттєвий вклад у проблематику, проте, незважаючи на значні досягнення в цій галузі, переважна більшість наукових

досліджень стосується фондового ринку, тоді як ринки криптовалют залишаються недостатньо висвітленими та потребують подальшого наукового опрацювання.

Водночас навіть використання аналізу ціни у поєднанні з обсягами не усуває проблему високого рівня шуму (noisy market). Механістичні показники здатні генерувати значну кількість сигналів, частина яких є статистично неінформативною або ж збитковою. Саме тому актуальним є поєднання механістичного підходу з алгоритмами машинного навчання. Сучасні дослідження показують, що моделі машинного навчання здатні точніше працювати з гетероскедастичними часовими рядами криптовалют, перевершуючи класичні статистичні моделі в задачах прогнозування волатильності та прибутковості [76].

У роботі зі статистично неінформативними або ж збитковими сигналами (подіями), машинне навчання використовується не для прямого прогнозування ціни, а для вирішення більш стійкої прикладної задачі – відсіювання хибно позитивних (не інформативних) подій, згенерованих механістичними показниками. Така постановка дозволяє змістити акцент з прогнозування цінового руху на оцінювання якості вже сформованих подій. У результаті система здатна відокремлювати статистично значущі події від шумових, підвищувати стабільність торгових рішень та знижувати кількість збиткових угод.

Отже, розробка методу аналізу та прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання є актуальним науково-практичним завданням, яке зумовлено необхідністю створення більш інформативних, адаптивних та стійких систем підтримки прийняття рішень, здатних працювати в умовах високої волатильності, гетероскедастичності та структурної складності фінансових часових рядів, забезпечуючи пояснюваність рішень, які базуються на фундаментальному ринковому механізмі: взаємодії попиту та пропозиції.

**Зв'язок роботи з науковими програмами, планами, темами.** Дисертаційна робота виконана відповідно до планів наукової і науково-технічної діяльності Державного університету інформаційно-комунікаційних технологій: «Забезпечення функціональної стійкості інформаційних систем підприємства в умовах впливу дестабілізуючих факторів із застосуванням нейронних мереж» (№ держ. реєстрації

0121U107501, термін виконання 2021-2025, ДУІКТ, м. Київ) (авторський внесок полягає у розробці методу машинного навчання для відсіювання хибно позитивних прогнозів); «Методи, моделі та програмні засоби інтелектуальної обробки даних фінансових ринків» (№ держ. реєстрації 0126U000001, термін виконання 01.2026-01.2029, ДУІКТ, м. Київ) (авторський внесок полягає в аналізі динаміки цінових тенденцій фінансових ринків з використанням машинного навчання).

**Метою дисертаційної роботи** є підвищення точності аналізу та прогнозування динаміки ринку криптовалют шляхом розробки методів аналізу та прогнозування на основі механістичного підходу та машинного навчання, а також архітектурних рішень їх програмної реалізації для формалізованого оцінювання взаємодії попиту та пропозиції, виявлення прихованих ринкових станів та ідентифікації інформативних торгових сигналів.

Для досягнення поставленої мети необхідно вирішити наступні **наукові завдання**:

1) провести аналіз методів технічного аналізу, алгоритмічної торгівлі та машинного навчання, дослідити особливості криптовалютного ринку як нестационарної системи та обґрунтувати роль механістичного підходу в задачах інтелектуальної обробки фінансових даних;

2) розробити вдосконалений метод механістичного аналізу на основі даних роздільних обсягів ринкових покупок та продажів для формалізованого оцінювання взаємодії попиту та пропозиції;

3) розробити алгоритмічну модель показника поглинання імпульсу (MAS) для ідентифікації прихованих фаз накопичення та розподілу активів;

4) розробити вдосконалений метод інтелектуальної фільтрації торгових сигналів із використанням ансамблевого машинного навчання для підвищення точності відбору інформативних ринкових подій та зменшення впливу шумових сигналів;

5) розробити архітектурні рішення реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи для

забезпечення ізоляції ресурсоемних процесів та спрощення інтеграції механістичних показників;

б) розробити програмно-технологічні рішення для підвищення обчислювальної продуктивності системи та провести експериментальне дослідження розроблених методів, моделей та програмних засобів на історичних даних для оцінки їхньої точності та обчислювальної продуктивності в реальних ринкових умовах.

**Об'єкт дослідження** – процеси аналізу та прогнозування динаміки ринку криптовалют в умовах високої волатильності та нестаціонарності фінансових часових рядів.

**Предмет дослідження** – методи, показники, архітектурні рішення та програмні засоби аналізу і прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання.

**Методи досліджень** базуються на механістичному підході, методах аналізу часових рядів, методах машинного навчання, статистичних методах, методах ретроспективного тестування, теорії прийняття рішень, алгоритмах та методах програмної інженерії.

**Наукова новизна отриманих результатів.** У процесі теоретичних і практичних досліджень, у дисертаційній роботі отримані наступні наукові результати:

1) удосконалено метод механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці, що дозволило формалізовано оцінювати взаємодію попиту та пропозиції в умовах високої волатильності та нестаціонарності ринку;

2) вперше розроблено показник поглинання імпульсу (Momentum Absorption Score, MAS), який ґрунтується на статистичному виявленні зон низької волатильності при аномально високих торгових обсягах за допомогою z-оцінок та процентильного аналізу і є складовою удосконаленого методу механістичного аналізу динаміки криптовалютних активів, що дозволило ідентифікувати приховані фази накопичення та розподілу активів, які передують значним ціновим рухам;

3) удосконалено метод прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу (механістичної ковзної та показника MAS) із застосуванням ансамблевого машинного навчання та класифікації прибутковості подій за методом потрійних бар'єрів, що дозволило підвищити точність ідентифікації інформативних сигналів та мінімізувати вплив ринкового шуму;

4) дістали подальшого розвитку архітектурні рішення реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи за рахунок впровадження модульної монолітної структури з розділеними контурами навчання та інференсу, що дозволило забезпечити ізоляцію ресурсоемних процесів та спростити інтеграцію механістичних показників.

### **Практичне значення одержаних результатів.**

1. Результати дослідження можуть бути використані при побудові інтелектуальних систем підтримки прийняття рішень у фінансовому секторі для забезпечення високоточного аналізу та прогнозування динаміки криптовалютного ринку в умовах високої волатильності та нестационарності часових рядів.

2. Використання технологій JIT-компіляції та паралелізації обчислень у програмній реалізації розроблених моделей дозволило досягти суттєвого підвищення обчислювальної продуктивності, що виражається у скороченні часу розрахунку складних показників з 2,0 до 0,6 секунди.

3. Наукові положення, теоретичні та експериментальні результати, отримані в дисертаційній роботі, впроваджені у практичну діяльність ФОП Новіцька А. В. (акт від 01.05.2026 р.), які дозволили підвищити обґрунтованість бізнес-рішень у комунікації з інвесторами, партнерами по біржі та розробки токеноміки для майбутніх клієнтів, зменшити відсоток хибно позитивних оцінок цінової динаміки токену компанії у наступні 3, 6 та 12 місяців на 11% та скоротити час на аналіз ринкових даних на 40% завдяки впровадженню програмно-технологічних засобів реалізації інтелектуальних систем аналізу даних.

4. Результати дослідження використовуються у науково-дослідній роботі Державного університету інформаційно-комунікаційних технологій (№ держ.

реєстрації 0121U107501 та 0126U000001), а також у навчальному процесі при викладанні дисциплін: «Технології Big Data» та «Програмування».

**Особистий внесок здобувача.** Усі наукові результати дисертації одержано автором самостійно. У друкованих працях, опублікованих у співавторстві, йому належить наступне: [1] – дослідження та аналіз простої ковзної середньої та механістичної ковзної, адаптація ковзних за допомогою експоненційної середньої; [2] – порівняльний аналіз механістичної та середньої ковзних зі застосуванням причинно-наслідкового аналізу, розробка алгоритму аналізу в розрізі висхідного на спадного тенденцій; [3] – розробка методу вдосконаленого механістичного підходу з використанням обсягів покупок та продажів, ретроспективне тестування методу з використанням стратегії ковзних середніх, порівняльний аналіз розроблених методів; [4] – розробка алгоритмічної моделі показника поглинання імпульсу, формалізація механістичної ковзної та MAS, розробка методу зі застосування машинного навчання для відсіювання хибно позитивних подій, оцінювання точності моделей; [5] – розробка архітектури прикладного програмного забезпечення, порівняльний аналіз, програмна реалізація механістичних показників, програмна реалізація методу машинного навчання для відсіювання хибно позитивних подій. [6] – дослідження методів аналізу ринку криптовалют, дослідження методів аналізу ринку за допомогою технічних показників, дослідження актуальності, місця та ролі механістичного підходу в аналізі динаміки ринку криптовалют; [7] – концептуалізація та розробка архітектури програмного забезпечення, алгоритми пошуку аномалій за допомогою інструментів механістичного підходу; [8] – дослідження методів аналізу торгових обсягів, розробка методу порівняння інструментів аналізу торгових обсягів, порівняльний аналіз; [9] – дослідження алгоритмів машинного навчання, дослідження проблематики довгого тренування моделей машинного навчання, аналіз наукових праць, розробка підходу до зменшення часу тренування моделей машинного навчання; [10] – дослідження методів оцінки алгоритмічних стратегій та методів оцінки прогнозів моделей машинного навчання, дослідження методів класифікації фінансових часових рядів на режими висхідних та спадних тенденцій, розробка підходу до оцінювання стратегій та моделей в розрізі висхідних та спадних тенденцій.



[11] – дослідження літератури стосовно машинного навчання у задачах відсіювання хибно позитивних подій, формалізація показників механістичного підходу в контексті формування подій, розробка методу машинного навчання для відсіювання хибно позитивних подій, що згенеровані показниками механістичного підходу, формалізація методу у задачу максимізації, аналіз та порівняння результатів; [12] – аналіз літератури, порівняльний аналіз методів пришвидшення обчислень показника поглинання імпульсу, розробка прикладного програмного забезпечення, тестування та порівняння результатів.

**Апробація результатів дисертації.** Основні положення дисертаційної роботи доповідалися та обговорювалися на Міжнародній науково-практичній конференції «Сучасні аспекти діджиталізації та інформатизації в програмній та комп'ютерній інженерії», 1 – 3 червня 2023 року, ДУІКТ, м. Київ; Всеукраїнській науково-технічній конференції «Застосування програмного забезпечення в інформаційно-комунікаційних технологіях», 24 квітня 2024 року, ДУІКТ, м. Київ; Всеукраїнській науково-практичній конференції молодих учених та студентів «Інформаційні технології в освіті, техніці та промисловості», 10 жовтня 2024 року, ІФНТУНГ, м. Івано-Франківськ, II Всеукраїнській науково-технічній конференції «Технологічні горизонти: дослідження та застосування інформаційних технологій для технологічного прогресу України і світу», 18 листопада 2024 року, ДУІКТ, м. Київ; Всеукраїнській науково-технічній конференції «Застосування програмного забезпечення в ІКТ», 24 квітня 2025 року, ДУІКТ, м. Київ; Всеукраїнській науково-технічній конференції "Виклики та рішення в програмній інженерії", 26 листопада 2025 року, ДУІКТ, м. Київ; VII Всеукраїнській науково-технічній конференції «Застосування програмного забезпечення в інформаційно-комунікаційних технологіях», 23 квітня 2026 року, ДУІКТ, м. Київ.

**Публікації.** Результати дисертації опубліковано в 12 наукових працях. Опубліковано статей – 5 [1 – 5], зокрема 5 статей [1 – 5] – у наукових фахових виданнях України з Переліку, затвердженого МОН України, з них – 1 стаття у науковому виданні, що індексується в наукометричній базі Scopus [2]. За матеріалами

виступів на науково-технічних та науково-практичних конференціях опубліковано 7 публікацій [6 – 12].

**Структура дисертації та її обсяг.** Дисертаційна робота складається зі вступу, 4 розділів, висновків, списку використаних джерел (155 найменування на 16 сторінках), 5 додатків (на 11 сторінках). Основний текст роботи викладено на 154 сторінках, рисунків – 58, таблиць – 32. Загальний обсяг роботи становить 195 сторінок.

## РОЗДІЛ 1. КОНЦЕПТУАЛЬНІ ЗАСАДИ ТА ОГЛЯД ДОСЛІДЖЕНЬ РИНКУ КРИПТОВАЛЮТ

### 1.1 Ринок криптовалют та його особливості

Ринок криптовалют – це динамічний та перспективний напрям глобального фінансового сектору, який пропонує унікальне поєднання технологічних інновацій та економічних можливостей. Криптовалюти – це децентралізовані цифрові валюти, що функціонують на основі блокчейну [1]. У свою чергу, блокчейн – це децентралізована цифрова база даних, яка зберігає інформацію у вигляді послідовного ланцюжка блоків, які підтверджуються за допомогою механізму консенсусу [2]. З моменту появи біткоїна [3] в 2009 році ринок криптовалют виріс експоненційно, охоплюючи тисячі альтернативних монет (альткоїнів) і децентралізованих фінансових продуктів. На відміну від традиційних фіатних валют, що випускаються та регулюються центральними банками, криптовалюти функціонують у децентралізованих мережах, полегшуючи транзакції в обхід звичних посередників.

Відмінні характеристики ринку криптовалют роблять його привабливим предметом для наукових досліджень: висока волатильність, швидкі інноваційні цикли та коливання ліквідності. На динаміку цін часто впливає поєднання технологічних факторів, настроїв інвесторів, макроекономічних умов і спекулятивної діяльності. Крім того, ринок працює в глобальному взаємопов'язаному середовищі, що створює як можливості, так і проблеми в таких сферах, як безпека, масштабованість та контроль за відповідністю діючому законодавству. Варто розуміти, що напрями застосування криптовалют можуть бути найрізноманітнішими, наприклад, Жебка В. та інші дослідили перспективу застосування криптовалют для фінансування в аграрному секторі України, зокрема для переробних підприємств [4] або ж Устименко В. та Поліщук Н. дослідили перспективи застосування криптовалют в енергетиці України [5].

З академічної точки зору, ринок криптовалют є конвергенцією багатьох дисциплін, такі як: інформатика, економіка, поведінкові фінанси та аналітика даних. Дослідження механізмів, які впливають на ціни криптовалют та стабільність ринку,

має важливе значення для розуміння їх потенційного впливу на глобальні економічні процеси.

У роботі Liang та ін. «На шляху до розуміння криптовалют: порівняльний аналіз криптовалют, іноземної валюти та акцій» [6] виконали комплексний порівняльний аналіз криптовалют, позиціонуючи їх відносно валютних і фондових ринків. Використовуючи щоденні дані про ціну закриття з січня 2015 року по листопад 2018 року, у дослідженні використовуються кореляційні матриці та методології дерева активів для вивчення п'яти критичних аспектів: волатильність, центральність, структура кластеризації, надійність і ризик. У висновках стверджують, що хоча криптовалюті спочатку позиціонувалися як цифрові валюти, їх ринкова динаміка більше схожа на фондовий ринок, ніж на ринок валют. Представлено п'ять основних особливостей та відмінностей ринку криптовалют:

1) висока волатильність: усі три фінансові ринки демонструють однакову поведінку щодо коливань цін, але криптовалюті демонструють підвищену волатильність;

2) центральність: спочатку Біткоїн був домінуючим активом на ринку криптовалют, але згодом кількість альтернативних цифрових валют збільшилась;

3) стійкість: ринок криптовалют менш стійкий порівняно з традиційними ринками;

4) структура кластеризації: на відміну від географічної кластеризації, яка спостерігається в іноземній валюті, та галузевої кластеризації в акціях, криптовалюті не демонструють стійких правил кластеризації, хоча й можуть об'єднуватися в спільні категорії;

5) ризики: криптовалюті характеризуються найвищим ризиком серед усіх ринків.

Біткоїн та інші криптовалюті часто протиставляються традиційним фінансовим інструментам та монетарним політикам. Наприклад, дослідження Нілкана Мерта та Мустафи Канера Тимура [7] розглядає зв'язок між цінами на Біткоїн та змінами пропозиції фіату у США, Європейському Союзі та Японії. Автори контекстуалізують появу Біткоїна як відповідь на обмеження та інфляційні тенденції

традиційних платіжних систем, особливо після фінансової кризи 2008 року та пандемії COVID-19. Тести Тода-Ямамото визначають короткостроковий причинно-наслідковий зв'язок між японською грошовою масою та ціною біткоїна. У той час як причинно-наслідковий зв'язок між пропозицією грошей у США та ціною на біткоїн сильно активувався після 2020 року, що збіглося з монетарною експансією під час кризи COVID-19. Висновки узгоджуються з оригінальною філософією Біткоїна як захисту від інфляції, спричиненої експансивною монетарною політикою.

Б'янкі Даніеле, Массімо Гвідолін та Мануела Педіо [8] у своїй роботі досліджують потенціал прогнозування та економічні наслідки криптовалют порівняно з традиційними активами, де підкреслюється відсутність систематичної передбачуваності традиційними факторами такі як динаміка фондового ринку або дорогоцінні метали, а увага інвесторів сильно змінюється в часі, бо дохідність криптовалют демонструє значний, хоча й динамічний, вплив змінних, пов'язаних із настроями інвесторів. Отримані дані підкреслюють потенціал криптовалют для сприяння диверсифікації портфеля та створення економічної цінності, особливо в нестабільних ринкових умовах. Порівняльний аналіз ринку криптовалют та інших типів фінансових ринків наведено в Таблиці 1.1.

Таблиця 1.1

Порівняльний аналіз ринку криптовалют та інших типів фінансових ринків

Критерій	Ринок криптовалют	Валютний ринок (Forex)	Фондовий ринок	Ринок сировини
1	2	3	4	5
Основний актив	Цифрові децентралізовані активи	Національні валюти	Акції компаній	Золото, нафта, газ, тощо
Принцип функціонування	Блокчейн та децентралізовані мережі	Центральні банки та міжбанківська система	Біржова інфраструктура	Товарні біржі та фізичний попит
Регулювання	Частково або фрагментарно регульований	Високий рівень регулювання	Високий рівень регулювання	Високий рівень регулювання
Централізація	Переважно децентралізований	Централізований	Централізований	Переважно централізований

Продовження таблиці 1.1

1	2	3	4	5
Режим роботи	Цілодобово (24/7)	24/5	Обмежений торговими сесіями	Обмежений торговими сесіями
Волатильність ринку	Дуже висока	Середня	Середня	Середня або висока
Ліквідність ринку	Нерівномірна	Дуже висока	Висока	Висока
Рівень ризику	Високий	Помірний	Помірний	Помірний
Вплив настроїв інвесторів	Дуже сильний	Помірний	Значний	Значний
Вплив макроекономічних факторів	Високий, але нестабільний	Визначальний	Визначальний	Визначальний
Механізм емісії	Алгоритмічний або програмно обмежений	Центральні банки	Емісія цінних паперів компаніями	Залежить від видобутку та виробництва

Таким чином, ринок криптовалют поєднує характеристики кількох типів фінансових ринків, проте має низку унікальних особливостей: децентралізовану архітектуру, алгоритмічні механізми емісії, підвищену волатильність та значну залежність від поведінкових факторів. На відміну від традиційних валютних і фондових ринків, криптовалютний ринок функціонує безперервно та характеризується високою швидкістю інноваційних змін. Це зумовлює як значний потенціал для диверсифікації та розвитку цифрової економіки, так і підвищені ризики для інвесторів та регуляторів.

## **1.2 Методи технічного аналізу в задачах прогнозування динаміки криптовалютного ринку**

### **1.2.1 Технічний аналіз та його складові**

Технічний аналіз – це методологія, яка використовується для оцінки та прогнозування руху цін на фінансові активи, включно з криптовалютами, шляхом аналізу історичних ринкових даних, таких як ціна, обсяг і торгова активність. На

відміну від фундаментального аналізу, який зосереджується на оцінці справедливої вартості активу шляхом вивчення пов'язаних економічних, фінансових та інших якісних і кількісних факторів, технічний аналіз спирається на виявлення закономірностей і тенденцій у ринкових даних, щоб зробити обґрунтовані прогнози щодо майбутньої динаміки цін.

Для того, щоб застосовувати технічний аналіз, необхідно дотримуватися трьох суворих припущень [9]:

1) ринок враховує все: технічний аналіз передбачає, що поточна ринкова ціна відображає всю наявну інформацію про актив. Це включає такі фундаментальні фактори як прибуток компаній або зовнішні фактори, як-от економічні дані та геополітичні події;

2) ринок рухається трендами: технічний аналіз вважає, що ринки проходять через висхідний, спадний та боковий тренди. Такі тренди визначаються циклами оптимізму, песимізму та більшого або слабкого попиту в різних моментах часу на основі емоцій страху та жадібності серед учасників ринку;

3) історія повторюється: технічний аналіз використовує різні моделі, засновані на припущенні, що тенденції цін мають тенденцію повторюватися з часом через послідовні аспекти людської психології. Класичні закономірності, такі як голова та плечі, канали, прапори, трикутники тощо, вказують на певні тенденції, такі як розвороти, продовження, консолідації, прориви тощо.

Висока волатильність і торгівля 24/7 робить крипторинки ідеальними для розпізнавання закономірностей. У [10] досліджено значний масив інструментів технічного аналізу такі як: теорію Доу, моделі розвороту, формування консолідації, визначення рівнів підтримки та супротиву, і т.д. Просте ковзне середнє (1.1) широко використовується дослідниками для аналізу активів [11]:

$$M_t(i) = \frac{1}{\tau} \cdot \sum_{i=t}^{t+\tau-1} x(i - \tau), i = \tau + 1, \dots, N, \quad (1.1)$$

де  $x(i - \tau)$  – часовий ряд на момент часу  $t$  за інтервал  $\tau$ .

Однією з найвідоміших торгових стратегій є кросовер, який полягає у використанні двох ковзних середніх ціни активу: швидкої та повільної ковзних середніх (або короткострокових і довгострокових ковзних середніх) [12]. Швидка

ковзна середня має коротший період, а повільна – довший. У випадку, коли швидка середня перетинає повільну середню знизу вгору, це сигнал покупки, а коли вона перетинає зверху вниз, це сигнал на продаж активу. Загалом ковзні середні широко використовуються як основа для багатьох нових алгоритмів: динамічна адаптація до нелінійних тенденцій за допомогою вилучення нових ознак використовуючи експоненціальну ковзну середню на основі відстаней [13], прогнозування композиційного часового ряду за допомогою баєсівської авторегресійної ковзної середньої Діріхле [14], адаптивна ковзна середня [15], рекурсивні правила торгівлі з ковзною середньою [16]. Смуги Боллінджера [17] складаються з трьох ковзних: середньої, яка є ковзним середнім ціни активу, і двох зовнішніх ковзних, які встановлені на заданій кількості стандартних відхилень вище та нижче середньої ковзної. Ці діапазони розширюються та звужуються залежно від коливань ціни активу. Широко застосовуються індикатори моментуму, такі як середній індекс спрямованого руху (Average Directional Movement Index), що використовується для оцінки сили тренду на фінансових ринках [18], Moving Average Convergence Divergence (MACD), який допомагає аналітикам визначати тенденції, імпульс і потенційні точки розвороту на фінансовому ринку. Він заснований на співвідношенні між двома ковзними середніми ціни активу [19]. Індекс відносної сили (RSI) – це осцилятор імпульсу, який використовується для вимірювання швидкості та амплітуди останніх змін ціни активу та допомагає визначити умови перекупленості або перепроданості, а також потенційні точки розвороту [20]. RSI коливається від 0 до 100, де значення вище 70 зазвичай вказує на стан перекупленості (можливість зниження ціни), а значення нижче 30 свідчить про перепроданість (можливість зростання ціни).

У роботі «Технічний аналіз на ринку Біткоїна: Можливості для торгівлі чи пастка для інвесторів?» [21] досліджується точність і прибутковість різних технічних торгових стратегій на ринку Біткоїна за період з 1 січня 2012 року по 20 серпня 2019 року. Дослідження показало, що торгові стратегії, засновані на щоденних даних, є більш прибутковими, ніж ті, що покладаються на дані всередині дня. Невідповідність точності пояснюється шумом, притаманним високочастотним даним, які генерують



численні фактори, багато з яких призводять до збиткових угод. Стратегія "купуй і тримай" (B&H), пасивний інвестиційний підхід, виявилася найприбутковішим варіантом в умовах торгівлі "всередині дня".

У роботі «Аналіз біржових даних на основі перетворення Гільберта-Хуанга» [22] запропонований метод прогнозування курсу акцій за допомогою перетворення Гільберта-Хуанга (Hilbert-Huang Transform, ННТ). Традиційні методи аналізу акцій, які часто базуються на середніх статистичних значеннях, мають проблеми з нестационарною та нелінійною природою даних фондового ринку. ННТ пропонує адаптивний підхід, який розкладає сигнали на функції внутрішнього режиму (Intrinsic Mode Functions, IMF) для аналізу тенденцій без затримки, властивої звичайним ковзним середнім. Дослідження робить висновок, що ННТ є надійним і точним методом аналізу часових рядів на фондових ринках і надає можливості для більш широкого застосування у фінансовому аналізі.

Досліджено потенціал стратегій технічного аналізу в отриманні прибутків [23], та розглянуто важливі обмеження, такі як вплив комісії за торгівлю та включення механізмів стоп-втрат (Stop-Loss). Отримані дані показують, що хоча методи технічного аналізу можуть досягти прибутку, що перевищує початкові інвестиції, витрати на комісії значно зменшують прибутковість торгової стратегії. Цікаво, що дослідження ставить під сумнів передбачувані захисні переваги механізму стоп-втрат. Всупереч передбачуваній меті обмеження ризику, включення механізму стоп-втрат негативно вплинуло на прогнозну здатність та точність досліджуваних методів.

### **1.2.2 Недоліки технічного аналізу**

Критичне дослідження Едварда Доусона та Джеймса Стілі [24] зосереджено на фондовому ринку Великобританії з метою відтворення та розширення аналізу візуальних закономірностей, такі як "голова і плечі", які характеризуються певною послідовністю розворотних точок. Автори спостерігали значні відмінності між умовним і безумовним розподілами прибутків. Однак, незважаючи на те, що закономірності виявляють варіації в моментах вищого порядку розподілу прибутку, вони не демонструють статистично значущих відмінностей у середніх прибутках. Це

підкреслює труднощі інтерпретації відмінностей у дисперсії, в контексті ефективності ринку, яка переважно базується на середній прибутковості. У сукупності отримані дані свідчать про те, що хоча технічні інструменти можуть давати уявлення про динаміку ринку, вони пропонують обмежену практичну користь для торгових стратегій. Це узгоджується з літературою, яка наголошує на труднощах отримання постійної прогностичної переваги від технічного аналізу.

У свою чергу, в роботі «Цінові тенденції та закономірності в технічному аналізі: Теоретичне та емпіричне дослідження» [25] досліджено взаємодію між когнітивними упередженнями та технічними торговими стратегіями. Досліджена структура ґрунтується на єдиному когнітивному упередженні, широко задокументованому в психологічній літературі, а саме на схильності людей вибірково шукати й інтерпретувати інформацію, щоб узгодити її з уже існуючими переконаннями. Інвестори раціонально інтерпретують великі, рідкісні сигнали. Однак на їхню інтерпретацію більш частих, менш інформативних сигналів систематично впливає пам'ять про останні успішні події. Це упередження створює моделі, що відповідають загальновизнаним торговим стратегіям. Такі висновки підкреслюють роль когнітивних спотворень у формуванні торгової стратегії.

В роботі «Що ми знаємо про прибутковість технічного аналізу?» запропоновано критику досліджень технічного аналізу [26]. Автори класифікують емпіричну літературу на дві окремі фази: ранні дослідження (1960–1987) і сучасні дослідження (1988–2004), висвітлюючи їхні методологічні підходи, висновки та обмеження. Ранні дослідження технічних правил торгівлі показали неоднозначні результати, докази прибутковості значно відрізнялися між ринками. Дослідження фондового ринку упродовж цього періоду загалом виявили обмежені прибутки, тоді як дослідження валютних і ф'ючерсних ринків часто повідомляли про значні чисті прибутки. Однак ці дослідження страждали від значних методологічних обмежень:

- 1) перевірка тільки однієї або двох торгових систем;
- 2) нехтування оцінкою ризиків, пов'язаних з правилами торгової стратегії;
- 3) відсутність суворої статистичної перевірки значущості прибутків;
- 4) відсутність оптимізації параметрів і перевірки поза вибіркою;

5) недостатня увага до упереджень відстеження даних.

Ці недоліки обмежили можливість узагальнення та надійність результатів, особливо в умовах, де ринкова динаміка та структури швидко змінювалися.

Також автори розглянули багато обмежень попередніх досліджень, підкресливши більш надійні методології. Серед них:

1) тестування більш широкого кола торгових систем;

2) включення заходів оцінки ризиків для правил торгової стратегії;

3) проведення статистичних тестів з використанням звичайних методів і складних методів, таких як методи початкового завантаження;

4) впровадження оптимізації параметрів і перевірки поза вибіркою для забезпечення надійності правил торгової стратегії.

Дослідження були розділені на сім окремих методологічних груп: стандартні, завантажувальні правила на основі моделі, генетичне програмування, нелінійні моделі, шаблони діаграм та інші. Серед 95 розглянутих сучасних досліджень 56 знайшли позитивні докази, що підтверджують технічні торгові стратегії, 20 повідомили про негативні результати, а 19 дали неоднозначні висновки. Основні висновки сучасних досліджень показали зниження прибутковості з часом. Наприклад, технічні правила торгівлі приносили прибуток на фондових ринках США до кінця 1980-х років, на валютних ринках до початку 1990-х років і на ф'ючерсних ринках до середини 1980-х років. Цей спад відображає зміну ефективності ринку, зменшення арбітражних можливостей і зростання конкуренції.

Незважаючи на докази прибутковості в певних контекстах, скептицизм щодо технічного аналізу залишається широко поширеним серед дослідників, які пояснюють цей скептицизм проблемами відстеження даних і потенційною незначністю прибутків після коригування комісійних витрат і ризику. Досліджена література підкреслює складну динаміку та суперечливу точність технічного аналізу (ТА) на фінансових ринках. Точність технічного аналізу в торгівлі залишається дискусійною темою, яка формується під впливом методологій, що розвиваються, і динаміки ринку. Майбутні роботи повинні надавати пріоритет дослідженням, які можна відтворити, передовій оцінці ризиків і безпосередній взаємодії з практиками,

щоб забезпечити повне розуміння технічних торгових стратегій, а також детально планувати експерименти та якісно перевіряти результати, щоб уникнути хибних висновків з ситуативних кореляцій. Порівняльний аналіз методів технічного аналізу наведено в Таблиці 1.2.

Таблиця 1.2

## Порівняльний аналіз методів технічного аналізу

Метод	Суть методу	Інструменти	Переваги	Недоліки	Дослідження
1	2	3	4	5	6
Просте ковзне середнє (SMA)	Усереднення ціни активу за певний період часу	SMA, EMA,	Простота реалізації, виявлення тренду	Слабка реакція на різкі зміни ринку	[11], [13]–[16]
Кросові ковзних середніх	Використання швидкої та повільної МА	Golden Cross, Death Cross	Добре працює на трендових ринках	Хибні сигнали у боковому русі	[12]
Смуки Боллінджера	Відхилення ціни від середньої	Bollinger Bands	Оцінка волатильності та відхилення	Хибний при сильних трендах	[17]
MACD	Співвідношення двох ковзних середніх	MACD, сигнальна лінія, гістограма	Виявлення тренду та імпульсу	Низька точність при боковому русі	[19]
RSI	Оцінка сили та швидкості зміни ціни	RSI	Оцінка зон інтересу покупців та продавців	Хибні сигнали при сильних трендах	[20]
ADX	Оцінка сили ринкового тренду	Average Directional Index	Оцінює силу тренду незалежно від напрямку	Не визначає напрям тренду	[18]

1	2	3	4	5	6
Графічні патерни	Повторювані цінові структури	Голова і плечі, трикутники, канали	Інтуїтивність	Суб'єктивність інтерпретації, слабка статистична підтвердженість	[10], [24]
Теорія Доу	Аналіз ринку через тренди та фази ринку	Первинні, вторинні тренди	Формує базу технічного аналізу	Суб'єктивність інтерпретації	[10]
Hilbert-Huang Transform (ННТ)	Адаптивний аналіз нелінійних та нестационарних часових рядів	IMF-компоненти, ННТ	Краще працює з нелінійними даними	Висока обчислювальна складність	[22]
Стратегія Buy & Hold	Довгострокове утримання активу	Довгострокова інвестиція	Низькі витрати, стійкість до шуму	Не захищає від глибоких просадок	[21]
Нелінійні та AI-підходи	Використання адаптивних моделей і машинного навчання	Нелінійні моделі, генетичне програмування	Краще виявлення складних залежностей	Ризик перенавчання	[26]

Порівняльний аналіз показує, що методи технічного аналізу суттєво відрізняються за принципами роботи, рівнем складності та точності застосування на криптовалютному ринку. Найбільш поширеними залишаються індикатори на основі ковзних середніх, RSI та MACD завдяки простоті реалізації та здатності виявляти тренди й точки розвороту. Водночас сучасні підходи, такі як ННТ, нелінійні моделі та методи машинного навчання, демонструють кращу адаптивність до нелінійної та

нестационарної природи криптовалютних часових рядів, однак характеризуються високою обчислювальною складністю та ризиком перенавчання моделей. У Таблиці 1.3 наведено переваги та недоліки технічного аналізу.

Таблиця 1.3

## Переваги та недоліки технічного аналізу

Аспект	Переваги	Недоліки
Прогнозування трендів	Дає змогу виявляти ринкові тенденції	Несвоєчасність сигналів (запізнюються за рухом ціни)
Автоматизація	Легко інтегрується в алгоритмічну торгівлю	Може генерувати хибні сигнали
Робота з крипторинком	Добре адаптується до високої волатильності та 24/7 торгівлі	Високочастотний шум знижує точність
Статистична надійність	Існують сучасні методи валідації та bootstrap	Багато стратегій не проходять перевірку поза вибіркою
Практична прибутковість	Може забезпечувати прибуток у певних ринкових умовах	Комісії та ризики часто нівелюють прибуток
Поведінковий аспект	Враховує психологію учасників ринку	Значна суб'єктивність інтерпретації
Гнучкість	Велика кількість індикаторів і стратегій	Високий ризик перенавчання моделей (overfitting)
Наукова підтвердженість	Частина досліджень підтверджує точність	Результати досліджень залишаються суперечливими

Технічний аналіз є важливим інструментом прогнозування динаміки криптовалютного ринку завдяки можливості автоматизації торгових стратегій, виявлення ринкових тенденцій та адаптації до високої волатильності. Однак точність технічного аналізу значною мірою обмежується наявністю ринкового шуму, запізненням сигналів, високою чутливістю до параметрів моделей і впливом транзакційних витрат. Крім того, результати багатьох стратегій втрачають статистичну значущість після перевірки поза вибіркою та врахування ризиків.

### **1.3 Методи аналізу торгових обсягів в задачах прогнозування динаміки криптовалютного ринку**

#### **1.3.1 Зв'язок торгових обсягів та ціни**

На фінансових ринках динаміка ціни та обсягу це дві з найважливіших ознак для торговців та інвесторів. У той час як рух цін часто привертає увагу учасників ринку, роль обсягу в торговій діяльності та аналізі залишається не менш важливою. Обсяг, який вимірює кількість акцій, контрактів або лотів, які обміняні (відповідно продані та куплені) упродовж певного періоду, діє як барометр активності учасників на ринку. Відображаючи інтенсивність покупок та продажів, обсяг дає торговцям та інвесторам цінну інформацію про силу чи слабкість цінових тенденцій, надійність ринкових сигналів і базову поведінку учасників, оскільки він відображає колективні дії учасників ринку та дає більш чітке уявлення про його динаміку.

Важливим аспектом обсягу є його зв'язок з ліквідністю. Активи з високим обсягом, який був обміняний упродовж певного періоду, як правило, більш ліквідні, що дозволяє торговцям відкривати та виходити з позицій з мінімальним прослизанням (різниця між очікуваною ціною угоди та ціною, за якою вона фактично виконується – це означає виконання ордеру за іншою ціною, ніж планувалося). Ліквідність особливо важлива для великих інституційних інвесторів, яким потрібно здійснювати значні угоди без істотного впливу на ринкову ціну. Для роздрібних торговців цінність ліквідних активів в тому, що високі обсяги й щільна книга лімітних ордерів знижують ймовірність маніпулювання цінами більшими учасниками (або памп-групами дрібних учасників) та підвищують надійність процесу технічного виконання ордеру на відміну від активів з невеликим обсягом і розсіяною книгою лімітних ордерів.

Зв'язок між обсягом торгів і прибутковістю активів досліджено у роботі «Динамічний зв'язок між прибутковістю акцій, обсягом торгів та волатильністю» [27]. Застосовано тести причинності Грейнджера, щоб оцінити, чи прибутки пояснюють обсяг чи навпаки. Використовуючи дані з дев'яти основних фондових ринків – США, Японії, Великобританії, Франції, Канади, Італії, Швейцарії, Нідерландів і Гонконгу –

дослідження визначає послідовні закономірності в динаміці обсягу торгів і прибутковості акцій, підтверджуючи позитивну кореляцію між обсягом торгів і абсолютним значенням змін цін на акції на всіх досліджуваних ринках. Загалом, результати вказують на двосторонній причинно-наслідковий зв'язок між зміною ціни та обсягом.

Аналіз обсягу особливо актуальний на ринках, де торговці стикаються з різними рівнями інформаційної невизначеності, оскільки обсяг здатен диференціювати сигнали високої та низької точності (наприклад, успішності або очікуваного прибутку), що дозволяє приймати більш обґрунтовані рішення [28]. Для певних фондових індексів знання історичних обсягів торгів, зокрема обсягів попереднього тижня, відіграє важливу роль у розумінні рівня цих індексів [29]. У дослідженні [30] виявлено значний причинний зв'язок Грейнджера від обсягу торгівлі до зміни цін у семи криптовалютах. Ці дані свідчать про те, що обсяг торгів може служити фактором для прогнозування руху цін, особливо в екстремальних ринкових умовах, таким чином пропонуючи цінну інформацію для торговців та інвесторів, які орієнтуються на нестабільні (або ж ризикові) ринки.

Досліджено [31] роль мережевої активності, такої як кількість унікальних адрес, що використовуються в мережі Bitcoin: існує позитивна кореляція між зростанням ціни на біткоїн і кількістю унікальних адрес, особливо як на тижневому, так і на денному часовому горизонті. Також обсяг торгів корелює з обсягом мережевих транзакцій та інтересом в пошукових рушіях, що вимірюється пошуком Google за словом «біткоїн». У дослідженні «Відстеження середньозважених за обсягом цін: Теоретичне та емпіричне дослідження» [32] було розроблено оптимальні торгові стратегії для відстеження ринкової середньозваженої за обсягом ціни (VWAP) з урахуванням різних моделей комісійних витрат. Дослідження показало, як обсяг торгів пов'язаний з дисперсією (або коливанням) прибутковості акцій, і як наслідок веде до вищої прибутковості в торгівлі.



### 1.3.2 Методи аналізу та прогнозування динаміки ринку криптовалют на основі торгового обсягу

Методи аналізу на основі обсягу використовуються для оцінки ринкової активності шляхом аналізу торгових обсягів. Ці методи допомагають визначити, чи рух ціни підтримується сильним чи слабким обсягом, що може вказувати на силу чи стійкість тренду. Один з таких індикаторів Балансовий обсяг (On-Balance Volume, або ж OBV) – це кумулятивний індикатор на основі обсягу, який додає або віднімає обсяг залежно від того, якою є ціна закриття торгів: вище чи нижче (1.2).

$$OBV_t = \begin{cases} OBV_{t-1} + V_t, & C_t > C_{t-1} \\ OBV_{t-1} - V_t, & C_t < C_{t-1} \end{cases}, \quad (1.2)$$

де  $C_t$  і  $V_t$  – ціна закриття та обсяг торгів відповідно в момент часу  $t$ , а  $OBV_{t-1}$  – це попереднє значення Балансового обсягу.

За визначенням, OBV збільшується, коли ціна зростає, і навпаки. Якщо ціна закривається вище, обсяг за день додається до загальної суми, а якщо ціна закривається нижче, то обсяг віднімається. OBV допомагає визначити, чи підтверджує обсяг ціновий тренд. Індикатор вказує на зростання ціни, коли він сам зростає зі зростанням ціни. На падіння ціни, коли OBV падає зі зниженням цін. Розбіжність між OBV і напрямом ціни може вказувати на потенційні розвороти. В одній з робіт досліджено [33] як OBV успішно прогнозує рух цін, перевершуючи стратегію «купуй і тримай» у шести з дев'яти досліджуваних індексів.

Індекс грошових потоків (Money Flow Index, або ж MFI) – це осцилятор (1.3), який використовує як ціну, так і обсяг, щоб ідентифікувати потік грошей в актив і з нього [34].

$$MFI_t(p) = 100 \frac{MFT_t^+(p)}{MFT_t^+(p) + MFT_t^-(p)}, \quad (1.3)$$

де  $MFT_t^+(p)$  – це позитивний грошовий потік (1.4), а  $MFT_t^-(p)$  – негативний грошовий потік (1.5):

$$MFT_t^+(p) = \sum_{\tau=t-p+1}^t \max(0; \operatorname{sgn}(TP_{\tau} - TP_{\tau-1}) \cdot MF_{\tau}), \quad (1.4)$$

та

$$MFT_t^-(p) = \sum_{\tau=t-p+1}^t \max(0; \operatorname{sgn}(TP_{\tau-1} - TP_{\tau}) \cdot MF_{\tau}), \quad (1.5)$$

де  $MF_t$  це грошовий потік (1.6):

$$MF_t = TP_t \cdot V_t, \quad (1.6)$$

де  $V_t$  – це торгові обсяги, а  $TP_t$  – середнє значення ціни в час  $t$ .

Цей осцилятор коливається від 0 до 100 і часто використовується для визначення умов перекупленості та перепроданості:

1) вище 80: актив вважається перекупленим, що вказує на можливий розворот або відкат;

2) нижче 20: актив вважається перепроданим, що свідчить про потенційну можливість покупки;

3) дивергенція: якщо ціна досягає нового максимуму або мінімуму, а MFI – ні, то це слугує попередженням про можливий розворот тренду.

Індекс накопичення/розподілу (Accumulation/Distribution Line, або A/D Line) – це індикатор (1.7), призначений для співвідношення ціни та обсягу, який діє як індикатор руху цін і використовується для виявлення розбіжностей між обсягом і ціною (тобто слабкості тренду) [35]:

$$A/D_t = A/D_{t-1} + V_t \cdot CLV_t, \quad (1.7)$$

де  $A/D_{t-1}$  – це попереднє значення індикатора,  $V_t$  – це обсяги торгів, а  $CLV_t$  – ціна за момент часу  $t$  (1.8):

$$CLV_t = \frac{(close_t - low_t) - (high_t - close_t)}{high_t - low_t}, \quad (1.8)$$

де  $close_t$  – ціна закриття,  $low_t$  – це найменша ціна, а  $high_t$  – це найбільша ціна за момент часу (інтервал)  $t$ .

A/D Line можна інтерпретувати наступним чином:

1) підтвердження трендів: якщо ціна зростає, а лінія A/D також зростає, тренд вважається сильним;

2) виявлення дивергенцій: якщо ціна зростає, а лінія A/D падає, це свідчить про слабкість тренду і можливе наближення розвороту.

Однак A/D Line не враховує цінові розриви (gaps), що може знизити її точність за певних умов волатильності ринку.

Середня зважена ціна за обсягом (Volume Weighted Average Price, або ж VWAP) обчислює середню ціну активу, зважену за обсягом торгів упродовж певного періоду (1.9). Це допомагає торговцям оцінити середню ціну, сплачену всіма учасниками за цей період часу.

$$VWAP = \frac{\sum(HLC_t \times Volume_t)}{\sum Volume_t}, \quad (1.9)$$

де  $HLC_t$  – це середнє значення ціни між  $close_t$  – ціна закриття,  $low_t$  – найменша ціна та  $high_t$  – найбільша ціна за момент часу (інтервал)  $t$ , а  $Volume_t$  – це обсяг торгів за момент часу (інтервал)  $t$ .

VWAP можна використовувати для визначення:

- підтримка та опір: VWAP виступає в ролі динамічного рівня підтримки або опору;
- моменти входу та виходу: можна розглядати покупку, коли ціна знаходиться вище VWAP, і продаж, коли вона нижче, або використовувати її як орієнтир для відкриття або закриття позицій.

Також VWAP може бути прив'язаний до конкретної події або часу, відображаючи середню собівартість для учасників ринку з заданого моменту.

В одній з робіт [36] досліджено стратегію трендової торгівлі VWAP, яка продемонструвала надзвичайну точність під час тестування за індексами QQQ (Invesco QQQ Trust, Series 1) і TQQQ (ProShares UltraPro QQQ) з січня 2018 року по вересень 2023 року. Підхід на основі VWAP, застосований до QQQ, дав 671% чистого прибутку, значно перевершивши прибутковість 126% від стратегії «купуй і тримай» за той самий період.

Осцилятор Клінгера [37] оцінює торговий обсяг із рухом цін. Осцилятор обчислюється з двох основних компонентів: сили обсягу (Volume Force, або ж VF) та експоненціальних ковзних середніх (Exponential Moving Average, або ж EMA). Сила обсягу відображає взаємодію між обсягом і напрямком руху ціни. Основна ідея полягає в тому, щоб призначити позитивне чи негативне значення залежно від того, вища чи нижча поточна ціна за попередню. Наступний крок передбачає застосування експоненціальних ковзних середніх до сили обсягу. Як правило, це вимагає

обчислення двох ЕМА, як правило, 34-періодної ЕМА та 55-періодної ЕМА Volume Force (1.10).

$$KVO = EMA_{34}(VF) - EMA_{55}(VF), \quad (1.10)$$

де VF це сила обсягу.

Осцилятор Клінгера можна використовувати наступним чином:

- перетин сигнальної лінії: сигнал на покупку виникає, коли лінія KVO перетинає сигнальну лінію зверху (особливо при низьких, від'ємних значеннях), тоді як сигнал на продаж виникає, коли вона перетинає її знизу;
- перетин нульової лінії: рух вище нуля вказує на те, що покупці контролюють ситуацію, тоді як рух нижче нуля вказує на те, що продавці контролюють ситуацію;
- дивергенція: сигнал на потенційний розворот, коли ціна досягає нового максимуму або мінімуму, але KVO не слідує за нею;
- визначення тренду: використання ЕМА для визначення загального напрямку тренду та торгівлі у напрямку цього тренду.

### 1.3.3 Ринкові та лімітні обсяги

Обсяги торгів містять наступні складові: ринкові ордери на покупку, ринкові ордери на продаж, лімітні покупки та лімітні продажі. Кожен з них відіграє вирішальну роль у формуванні торговельного середовища та впливає на аналіз активів і торгові стратегії.

Ринкові ордери – це вказівки щодо купівлі або продажу активу за поточною найкращою доступною ціною [38]. Ринковий ордер на покупку виконується за найнижчою доступною ціною лімітної заявки на продаж, тоді як ринковий ордер на продаж відповідає найвищій доступній ціні лімітної заявки на покупку. Ринкові ордери дозволяють швидко відкривати та закривати угоди за поточною ціною активу.

З іншого боку, лімітні заявки на покупку вказують конкретну ціну за якою учасник хоче купити актив, а лімітні заявки на продаж вказують конкретну ціну за якою учасник хоче продати актив. Ці замовлення розміщуються в книзі заявок і залишаються там до виконання, скасування або досягнення ринком зазначеної ціни [39, 40]. Незважаючи на те, що ринкові ордери гарантують швидке виконання, вони

виконуються за поточною ціною. Лімітні ордери, навпаки, забезпечують контроль ціни, але не гарантують виконання, оскільки ринок може ніколи не досягти заданих рівнів ціни в лімітних заявках [41, 42].

Високий обсяг торгів свідчить про активну участь і ліквідність, тоді як низький обсяг свідчить про слабку активність та низьку ліквідність. Обсяг має вирішальне значення для ліквідності ринку, гарантуючи, що покупці та продавці можуть здійснювати обміни, не спричиняючи значних коливань цін. Він також відіграє ключову роль у визначенні ціни, оскільки активна торгівля відображає консенсус щодо вартості активу. Обсяги купівлі та продажу на ринку є прямими індикаторами настроїв ринку. Домінування ринкових ордерів на покупку свідчить про позитивні настрої, тоді як переважання ордерів на продаж вказує на негативні (зниження ціни). Аналіз цих обсягів допомагає торговцям зрозуміти психологічний стан учасників ринку. Ринкові обсяги купівлі та продажу часто передують ціновим рухам. Наприклад, різке збільшення обсягу купівлі може підштовхнути ціни вгору, тоді як збільшення обсягу продажу може знизити ціни. Цей зв'язок дозволяє аналітикам передбачати зміни цін і використовувати їх [43, 44, 45, 46].

На ринку криптовалют значні стрибки обсягів покупок часто відбуваються під час подій, пов'язаних із новинами, таких як схвалення регуляторних органів або великі партнерства. І навпаки, різке зростання обсягів продажів може відбуватися після негативних подій.

Лімітні ордери формують книгу ордерів (рис. 1.1) – візуальне представлення всіх ордерів на покупку та продаж. Агрегування лімітних обсягів пропозиції та попиту створює глибину ринку, демонструючи рівні попиту та пропозиції на різних цінових рівнях. Заявки на продаж розташовані у верхній частині, тоді як заявки на покупку в нижній. Учасники можуть встановлювати бажану ціну та обсяг своєї заявки. Зазвичай можна бачити агреговану книгу лімітних заявок, де ордери об'єднуються довкола цінових рівнів для простішого візуального сприйняття.



Рис. 1.1 – Книга лімітних заявок (заявки на покупку – зелений колір, а заявки на продаж – червоний)

Велика концентрація лімітних заявок на покупку на певних цінових рівнях часто слугує ознакою попиту, запобігаючи подальшому падінню цін і, відповідно, концентрація лімітних заявок на продаж є ознакою пропозиції, що запобігає зростанню цін. Застосування ринкових ордерів має на меті швидко закрити угоду, тоді як лімітні ордери доречні для накопичення позиції, не переплачуючи [47, 48].

Загальний, або ж сумарний ринковий обсяг (Volume, або ж Volume Total) – це сума обсягів ринкових покупок (Volume Buy) та обсягів ринкових продажів (Volume Sell). Формула сумарних ринкових обсягів наступна (1.11):

$$V_t = V_{buy,t} + V_{sell,t}, \quad (1.11)$$

де  $V_t$  – це сума ринкових обсягів покупок  $V_{buy,t}$  та  $V_{sell,t}$  за часовий інтервал  $t$ .

На рис. 1.2 зображено динаміку різних типів обсягів, де прослідковується загальний тренд на збільшення та зменшення обсягів у різні періоди часу.




Рис. 1.2 – Динаміка ринкових обсягів торгової пари BTC/USDT

Різниця ринкових обсягів (Volume Delta) – це різниця обсягів покупок та обсягів продажів (1.12).

$$VD_t = V_{buy,t} - V_{sell,t}, \quad (1.12)$$

де  $VD_t$  – це різниця ринкових обсягів покупок  $V_{buy,t}$  та  $V_{sell,t}$  за часовий інтервал  $t$ .

На рис. 1.3 зображено динаміку різниці ринкових обсягів. Таке представлення даних зрозуміліше демонструє динаміку ринкових обсягів.




Рис. 1.3 – Динаміка різниці ринкових обсягів торгової пари BTC/USDT

В більшості ситуацій позитивна ринкова дельта обсягів візуально корелює зі зростанням ціни, а негативна – з падінням. Однак існують випадки, коли дельта обсягів та ціна поведуться не так як очікується. На рис. 1.4 червоними стрілками вказано на момент у часі, коли ціна зросла (зелена цінова свічка), але дельта обсягів помітно негативна відносно попередніх значень, а зеленими стрілками вказано на ситуацію, коли ціна закриття нижча за ціну відкриття (червона цінова свічка), але дельта обсягів помітно позитивна. Обидва випадки мають довгі цінові “вуса”: діапазон між ціною закриття та найвищою ціною у першому випадку та діапазон між ціною закриття на найменшою ціною в другому випадку. Обидва випадки не мають аномально великі або малі діапазони між цінами відкриття та закриття. Загалом, такі ситуації є аномальними, оскільки помітно вирізняються з поміж інших.





Рис. 1.4 – Аномальні ситуації торгової пари BTC/USDT

Кумулятивна (або ж накопичувальна) дельта обсягів (Volume Delta Cumsum) – це індикатор у якого кожне наступне значення є сумою всіх попередніх дельт обсягів (1.13).

$$VDC_t = \sum_{i=1}^t VD_i, \quad (1.13)$$

де  $VD_i$  – це дельта ринкових обсягів у момент часу  $i$ .

На рис. 1.5 зображено кумулятивну дельту обсягів. Таке візуальне представлення дає чіткіше розуміння загальної зміни в обсягах за обраний період відносно зміни ціни. Наприклад, можна оцінити як загальна домінація ринкових покупок над продажами впливала на зміну ціни. Домінують покупки та ціна зростає – очікувано, а якщо не зростає або ж падає – то ні, тобто це аномально.



Рис. 1.5 – Дельта обсягів та кумулятивна дельта обсягів торгової пари BTC/USDT

Баланс обсягів (Volume Balance) – інструмент аналізу обсягів, який обчислює співвідношення обсягів покупок до сумарних ринкових обсягів (1.14):

$$VB_t = \frac{V_{buy,t}}{V_t} \cdot 100. \quad (1.14)$$

На рис. 1.6 зображено баланс обсягів та ковзну середню балансу обсягів за останні 36 значень (Volume Balance MA). Візуально баланс обсягів та дельта обсягів часто збігаються, однак ситуації, коли вони мають негативну кореляцію, може вказувати на аномальні умови й надавати підказки про відкриття торгової угоди.




Рис. 1.6 – Баланс та дельта обсягів торгової пари BTC/USDT

Загалом, ціну рухають ринкові заявки на покупку або на продаж, коли як лімітні заявки стримують ринкові обсяги. Те, як взаємодіють лімітні та ринкові обсяги, формує ціну. Аномальні випадки такі як, наприклад, ринкові покупки, які не призводять до зростання ціни, можуть вказувати на наявність лімітного продавця, який стримує це зростання. Аналіз обсягів дає можливість більш аргументовано ухвалювати рішення на фінансових ринках, спираючись на його фундаментальні механізми. В Таблиці 1.4 представлено порівняння методів аналізу на основі торгових обсягів.

## Порівняння методів аналізу на основі торгових обсягів

Метод	Тип	Вимірює	Переваги	Обмеження
OBV	кумулятивний	напрям накопичення обсягу	простий, ранні сигнали	ігнорує волатильність
MFI	осцилятор	грошовий потік	добре враховує ціну та обсяг	нестійкий до шуму
A/D line	кумулятивний	накопичення/розподіл	чутливий до розворотів	нестійкий до шуму
VWAP	середня ціна	“справедлива ціна”	стабільний бейзлайн	чутливий до параметрів
Klinger Oscillator	осцилятор	тиск обсягу	добре знаходить тренди	складний, чутливий до параметрів
Volume Delta	потоки	активність ринку	пряма оцінка попиту	не нормалізований
Cumulative Delta	кумулятивний	довгостроковий тиск	оцінює тиск покупців та продавців	накопичує шум
Volume Balance	співвідношення	баланс попиту	нормалізований	не враховує ціну

Розглянуті методи аналізу торгових обсягів формують взаємопов'язану систему, які по-різному відображають взаємодію між ціною, ліквідністю та ринковими потоками. Частина підходів (OBV, A/D, Klinger) фокусується на підтвердженні або ослабленні тренду через кумулятивну поведінку обсягів, тоді як осцилятори (MFI) дозволяють виявляти локальні екстремуми та потенційні розвороти. VWAP виступає як референтна “справедлива” ціна, а метрики дельти та балансу обсягів безпосередньо описують домінування покупців або продавців на ринку. Узагальнено, жоден із методів не є універсальним, однак їх поєднання має бути доцільним в контексті мультифакторного підходу до прогнозування динаміки

криптовалютного ринку, де обсяг виступає ключовим провідним індикатором ціни та ліквідності.

#### **1.4 Основні напрямки та завдання дисертаційного дослідження**

Ринок криптовалют характеризується децентралізованою архітектурою, функціонуванням у режимі 24/7 та високою волатильністю, що суттєво відрізняє його від традиційних фінансових ринків. Проведений аналіз існуючих методів та підходів (Таблиця 1.5) до прогнозування його динаміки демонструє, що класичний технічний аналіз, попри свою популярність та простоту автоматизації, має критичні недоліки. Зокрема, методи, що базуються виключно на історичній ціні, генерують запізнілі сигнали, страждають від високочастотного ринкового шуму та часто втрачають статистичну значущість під час перевірки поза вибіркою.

З іншого боку, методи аналізу торгових обсягів (такі як Volume Delta, Кумулятивна дельта, Баланс обсягів) виступають провідними методами оцінки ліквідності. Вони дозволяють оцінити реальний баланс між попитом і пропозицією, розкриваючи агресію ринкових учасників та прихований тиск лімітних ордерів. Проте лінійна інтерпретація обсягів ускладнюється нестаціонарною природою крипторинку та наявністю аномальних ринкових ситуацій.

Дослідження підтверджують, що найбільш перспективним вектором розвитку є використання адаптивних нелінійних моделей. Отже, жоден ізольований метод не здатний забезпечити стабільну прогностичну перевагу. Це зумовлює актуальність розробки методів аналізу та прогнозування динаміки криптовалютного ринку на основі торгових обсягів та машинного навчання. Такий підхід дозволить поєднати торгові обсяги (як індикатора ринкової мікроструктури) із алгоритмами машинного навчання для виявлення прихованих нелінійних закономірностей.

Механістичний підхід дозволяє розглядати обсяг торгів як змінну, що аналогічна до маси у фізичних моделях, що відкриває нові перспективи в аналізі ринкової динаміки. Запропонований у дослідженні підхід спрямований на вдосконалення алгоритмів прогнозування ціни активів шляхом інтеграції обсягових показників та методів машинного навчання.

## Порівняльний аналіз методів прогнозування динаміки ринку криптовалют

Група методів	Основні інструменти	Дані	Переваги	Обмеження
Класичний технічний аналіз	SMA, MACD, RSI, Смуги Боллінджера	Історія цін	Простота реалізації, автоматизація, виявлення загальних трендів	Запізнення сигналів, висока чутливість до ринкового шуму
Аналіз кумулятивних обсягів	OBV, A/D Line, Кумулятивна дельта (VDC)	Зв'язок ціни та загального обсягу торгів	Формує ранні сигнали розворотів, відображає тиск ринку.	Накопичує шум, не враховує локальну волатильність
Аналіз ринкової мікроструктури	Volume Delta, Volume Balance	Деталізований потік ордерів	Пряма оцінка попиту та пропозиції, індикація агресії ринку та прихованої ліквідності.	Вимагає високочастотних даних, не нормалізований, складний для інтерпретації без ціни.
Нелінійні моделі та Машинне навчання (ML)	Логістична регресія, Дерева рішень, Нейронні мережі	Мультифакторні дані (ціна, обсяги, сентимент)	Адаптивність до нелінійної та нестационарної природи крипторинку	Висока обчислювальна складність, перенавчання (overfitting)

**Метою дисертаційної роботи** є підвищення точності аналізу та прогнозування динаміки ринку криптовалют шляхом розробки методів аналізу та прогнозування на основі механістичного підходу та машинного навчання, а також архітектурних рішень їх програмної реалізації для формалізованого оцінювання взаємодії попиту та пропозиції, виявлення прихованих ринкових станів та ідентифікації інформативних торгових сигналів.

Для досягнення поставленої мети необхідно вирішити наступні **наукові завдання:**

1) провести аналіз методів технічного аналізу, алгоритмічної торгівлі та машинного навчання, дослідити особливості криптовалютного ринку як нестационарної системи та обґрунтувати роль механістичного підходу в задачах інтелектуальної обробки фінансових даних;

2) розробити вдосконалений метод механістичного аналізу на основі даних роздільних обсягів ринкових покупок та продажів для формалізованого оцінювання взаємодії попиту та пропозиції;

3) розробити алгоритмічну модель показника поглинання імпульсу (MAS) для ідентифікації прихованих фаз накопичення та розподілу активів;

4) розробити вдосконалений метод інтелектуальної фільтрації торгових сигналів із використанням ансамблевого машинного навчання для підвищення точності відбору інформативних ринкових подій та зменшення впливу шумових сигналів;

5) розробити архітектурні рішення реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи для забезпечення ізоляції ресурсоємних процесів та спрощення інтеграції механістичних показників;

6) розробити програмно-технологічні рішення для підвищення обчислювальної продуктивності системи та провести експериментальне дослідження розроблених методів, моделей та програмних засобів на історичних даних для оцінки їхньої точності та обчислювальної продуктивності в реальних ринкових умовах.

**Об'єкт дослідження** – процеси аналізу та прогнозування динаміки ринку криптовалют в умовах високої волатильності та нестационарності фінансових часових рядів.

**Предмет дослідження** – методи, показники, архітектурні рішення та програмні засоби аналізу і прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання..

**Методи досліджень** базуються на механістичному підході, методах аналізу часових рядів, методах машинного навчання, статистичних методах, методах ретроспективного тестування, теорії прийняття рішень, алгоритмах та методах програмної інженерії

## **Висновки до розділу 1**

Проведено дослідження існуючих методів аналізу та прогнозування динаміки криптовалютного ринку. Розглянуто загальні характеристики ринку криптовалют, який є децентралізованим, високо волатильним і схильним до впливу багатьох факторів включно з настроями інвесторів та макроекономічними умовами. Відзначено його подібність до фондових ринків за рівнем волатильності, а також відмінності у структурі кластеризації та рівні ризику. Детально розглянуто методи технічного аналізу, що широко використовуються для прогнозування ринкових тенденцій. Підкреслено, що технічний аналіз має як переваги, так і обмеження, особливо в умовах динамічного ринку криптовалют. Вказано, що точність технічного аналізу залежить від належного вибору параметрів та адаптації до ринкових умов.

Підкреслено важливість методів аналізу торгових обсягів, які можуть забезпечити додаткові можливості для оцінки ринкової ситуації. Встановлено, що обсяг торгів відіграє ключову роль у підтвердженні трендів і може бути надійним фактором для прогнозування ринкових змін. Розглянуто основні методи аналізу обсягу, які використовуються для оцінки сили тренду та можливих точок розвороту. Проаналізовано взаємозв'язок між ринковими та лімітними ордерами, їх вплив на формування ціни та ліквідність ринку. Показано, що аналіз обсягів дозволяє отримати додаткові фактори для прийняття торгових рішень, особливо в поєднанні з іншими методами прогнозування.

Жоден ізольований метод не здатний забезпечити стабільну прогностичну перевагу. Таким чином, існує реальна потреба у створенні нових комбінованих методів, що поєднують аналіз обсягів та передові алгоритми машинного навчання для підвищення точності прогнозування ринкових змін в умовах високої волатильності та нестационарності криптовалютного ринку.



## **РОЗДІЛ 2. МЕХАНІСТИЧНИЙ ПІДХІД ТА МАШИННЕ НАВЧАННЯ В ЗАДАЧАХ ПРОГНОЗУВАННЯ РИНКОВИХ ТЕНДЕНЦІЙ**

### **2.1 Еконофізика в економіці та фінансах**

У роботі [49] описане загальне розуміння ролі еконофізики в економічних процесах. Автори вважають, що економічні теорії випливають з максимізації очікуваної корисності шляхом застосування фундаментальних принципів до різних сценаріїв. Еконофізика, термін, введений Розаріо Мантенья та Х. Юджином Стенлі на конференції Statphys-Kolkata у 1995 році, повторює тенденції міждисциплінарних напрямів, таких як астрофізика та біофізика. Еконофізика досліджує паралелі між економікою та фізикою, використовуючи методи статистичної фізики. Зв'язок між фізикою та економікою давно встановлений. Фізика відіграла вирішальну роль у формуванні формальної економічної теорії. Вплив теорії відносності та квантової механіки поглибив теоретичні межі, об'єднавши простір, час і фундаментальні сили. Статистична механіка, розроблена в 19 столітті Максвеллом, Больцманом і Гіббсом, заклала основу, описавши поведінку атомів за допомогою розподілу ймовірностей. Вплив фізики на економіку налічує понад два століття. Н.-Ф. Канард (1801) порівнював попит і пропозицію з протилежними фізичними силами. До 1990-х років фізики все частіше застосовували статистичну фізику до фінансових та економічних систем, що призвело до активної появи міждисциплінарних досліджень, нових журналів і конференцій.

Еконофізика застосовує теорії, що засновані на відповідних теоріях з фізики, до економіки, зосереджуючись на відсоткових ставках, коливаннях фондового ринку та фінансових системах. Аналогії виводяться з таких фізичних концепцій, як турбулентність, фрактали та енергетичні стани [50]. Методи статистичної фізики почали впливати на економіку, і навпаки, демонструючи міждисциплінарний потенціал. Фізики, які мають досвід роботи з експериментальними даними, застосовують ці інструменти для виявлення закономірностей у соціальних науках, економіці та фінансах. Еконофізика кидає виклик традиційним економічним

моделям, розглядаючи фінансові ринки як адаптивні складні системи, що складаються з учасників, що мають як спільні так і протилежні цілі.

Ранні фізики, які вивчали фінансові ринки, шукали закони стабільності, але виявили, що ринки за своєю суттю є нестаціонарними. Адаптивні складні системи розвиваються на основі колективної поведінки агентів, тобто їхні емпіричні розподіли не є фіксованими [51]. Три ключові умови визначають складні системи:

- 1) вони містять велику кількість взаємодіючих елементів;
- 2) ці субодиноки взаємозалежні;
- 3) їх взаємодія є нелінійною.

Адаптивні комплексні системи додають ще один рівень: елементи системи пристосовуються до змін середовища, генеруючи нові системні властивості. Крім того, організовуючи адаптивні комплексні системи, вводяться індивідуальні елементи, що змінюють власні властивості та поведінку по відношенню до властивостей і поведінки одиначної системи, іноді запроваджуючи показник ефективності мережі [52, 53].

Ентропія, фундаментальна концепція як у термодинаміці, так і в теорії інформації, застосовувалася до фінансів як міра невизначеності. Ентропія Шеннона, яка широко використовується для кількісного розрахунку невизначеності, була застосована для оптимізації фінансових портфелів як інструмент мінімізації ризику, а інформація за Фішером фіксує структуру інформації в межах розподілу ймовірностей. Дослідження показали, що мінімізація фінансового ризику узгоджується з мінімізацією інформації за Фішером, пропонуючи новий підхід до оптимізації портфеля [54]. Концепція само організованої критичності (SOC) використовується для моделювання крахів ринку, різких крахів і раптової нестачі ліквідності в криптовалютах. Моделі SOC допомагають торговцям і регуляторам передбачати катастрофічні події на ринку [55]. Еконофізика застосовує різні аналогії, щоб зрозуміти арбітражні можливості на крипторинках. Такі поняття, як ентропія та фазові переходи, допомагають торговцям визначити, коли ринки неефективні та готові для стратегій арбітражу. Підходи, засновані на статистичній механіці, дозволяють точніше оцінювати ризики в середовищах високочастотної торгівлі

(High-Frequency Trading, або ж HFT) [56]. Еконофізика може спиратися на моделі Айзінга в магнетизмі, щоб кількісно визначити настрої колективних інвесторів, допомагаючи аналітикам виявити раціональні та ірраціональні настрої [57].

Синергія між еконофізикою та машинним навчанням покращує прогнозування, оцінку ризиків і розуміння ринкової динаміки. Алгоритми машинного навчання, такі як глибоке навчання та навчання з підкріпленням, покращують прогнозування часових рядів, моделювання волатильності та аналіз ринкових тенденцій. Алгоритми навчання без вчителя, як-от кластеризація та виявлення аномалій, допомагають виявляти фінансові бульбашки, миттєвий збій, системні ризики, дисбаланс між пропозицією та попитом, а також маніпуляції. Нейронні мережі та генеративні моделі симулюють і аналізують складну економічну поведінку, наприклад моделі на основі агентів і механізми формування цін [58]. Алгоритмічна торгівля та високочастотні торгові стратегії також широко використовують алгоритми машинного навчання в прийнятті рішень на основі даних.

## **2.2 Місце та роль механістичного підходу в задачах прогнозування ринкових тенденцій**

Механістичний підхід до прогнозування ринкових тенденцій є перетином традиційного аналізу обсягів та моделювання на основі фізичних законів, що робить його тісно пов'язаним із принципами еконофізики. Механістичний підхід, запроваджений Марселем Ауслосом і Катрін Івановою [59], включає обсяг транзакцій як динамічну змінну, яка є аналогією до поняття маси у фізиці, проводячи прямі аналогії з класичною механікою.

Ідея механістичного підходу полягає у тому, щоб поєднати традиційні методи технічного аналізу та аналізу обсягів з фізичними законами, а також спиратися не тільки на ціну, а і на об'єм, розглядаючи його як фізичну масу активу. Аналогія маси: обсяг транзакції розглядається як залежна від часу маса, що впливає на узагальнений імпульс і обчислення енергії. Узагальнений імпульс визначається як добуток цієї «маси» та швидкості ціни, виявляючи більш глибоку динаміку між змінами ціни та обсягу.

Розглянемо  $V(t)$  як обсяг транзакцій активу за ціною  $x(t)$  у момент часу  $t$ . Узагальнений імпульс  $\tilde{R}_\tau$  за інтервал часу  $\tau$  можна визначити через (2.1):

$$\tilde{R}_\tau(t) = \frac{V(t)}{\langle V(t) \rangle_\tau} \cdot \frac{x(t) - x(t-\tau)}{\tau}, \quad t = \tau + 1, \dots, N, \quad (2.1)$$

де  $V(t)$  – це обсяг транзакцій у момент часу  $t$ , загальний обсяг транзакцій за інтервал  $\tau$  це  $\langle V \rangle_\tau \tau = \sum_{i=1}^{\tau} V(i)$ , а середня швидкість зміни ціни за інтервал часу  $\tau$  це  $\frac{x(t) - x(t-\tau)}{\tau}$ .

Розраховуючи це, ми вводимо деяку фінансову аналогію з узагальненою залежною від часу масою  $m(t)$  дифузного об'єкту. Загальний обсяг у знаменнику (2.1) вводиться з метою нормалізації значень.

Отже, ми можемо ввести поняття “маси” (2.2) та “швидкості” (2.3), через стандартне поняття фізичного моменту (2.4):

$$m(t) = \frac{V(t)}{\langle V \rangle_\tau}, \quad (2.2)$$

де  $V(t)$  – це обсяг транзакцій у момент часу  $t$ , а загальний обсяг транзакцій за інтервал це  $\langle V \rangle_\tau \tau = \sum_{i=1}^{\tau} V(i)$ .

$$v(t) = \frac{\Delta x}{\tau}, \quad (2.3)$$

де  $\Delta x$  це зміна ціни за інтервал  $\tau$ .

$$\tilde{R}_\tau = p(t) = \sum_{i=t}^{t+\tau-1} m(i) \cdot v(i), \quad (2.4)$$

де  $m(i)$  – це “маса” активу, а  $v(i)$  – це “прискорення” активу, тобто швидкість зміни ціни.

Таким чином, ми враховуємо ціну та об'єм активу і таку взаємодію можна представити як класичну силу  $F$ , яка діє на об'єкт (фондовий або ринковий індекс).

Для практичного застосування узагальненого моменту пропонують використовувати ковзні середні. Просте ковзне середнє  $M_t(i)$  механістичного імпульсу  $R$  за інтервал часу  $\tau$  визначається як (2.5):

$$M_t(i) = \frac{1}{\tau} \sum_{i=t}^{t+\tau-1} R(i - \tau), \quad i = \tau + 1, \dots, N, \quad (2.5)$$

де  $R$  – це механістичний імпульс за останні  $\tau$  точок даних.

Стратегія застосування механістичного імпульсу полягає у використанні двох ковзних середніх на часовому ряді узагальненого моментуму: швидка і повільна ковзні. Швидка ковзна має менший період, а повільна – більший. У випадку, коли швидка ковзна перетинає повільну ковзну знизу вгору – то це ознака на зростання ціни активу, а при перетині згори вниз – то це ознака на падіння ціни активу. На рис. 2.1 зображено стратегію ковзних середніх, запропоновану авторами механістичного підходу.




Рис. 2.1 – Порівняння ковзних середніх, узагальненої енергії та узагальненого моментуму на акціях IBM у 1999 році для трьох часових горизонтів, тижневого (рожевий), місячного (помаранчевий) та річного (штрих-пунктир) [59]

Таким чином, механістичний підхід переосмислює традиційний технічний аналіз з точки зору еконофізики, враховуючи обсяг торгів як динамічний фактор, що впливає на цінові тенденції. Поєднуючи концепції фізики з фінансовими даними, цей підхід поглиблює розуміння та посилює прогнозу точність аналізу ринку.

## **2.3 Машинне навчання в задачах прогнозування ринкових тенденцій**

### **2.3.1 Основні поняття та алгоритми машинного навчання**

Точне прогнозування ринкових тенденцій має вирішальне значення для компаній, інвесторів та торговців. Традиційні методи прогнозування часто спираються на історичні дані та нескладні статистичні моделі, яким може бути важко вловити складність і швидкість змін на ринках.

Машинне навчання – це підмножина штучного інтелекту (AI), яка зосереджена на розробці алгоритмів, які здатні навчатися та робити прогнози на основі даних. У сучасну цифрову епоху, коли величезні обсяги даних генеруються щосекунди, ML став ключовим інструментом для аналізу інформації та автоматизації процесів прийняття рішень. Алгоритми ML широко використовуються в різних галузях: охорону здоров'я, фінанси, кібербезпеку, розумні міста, тощо.

Машинне навчання стало дієвим інструментом для прогнозування ринкових тенденцій, забезпечуючи розуміння на основі даних, можливості адаптивного навчання та покращену точність прогнозування. Алгоритми ML можуть виявляти приховані закономірності, аналізувати настрої та реагувати на динамічні ринкові умови з більшою точністю, ніж традиційні підходи. Алгоритми ML можна розділити на чотири основні типи: навчання з вчителем, навчання без вчителя, напівконтрольоване навчання та навчання з підкріпленням. Кожен тип має свої напрями застосування [60].

Навчання з вчителем передбачає навчання алгоритму на розмічених даних. Алгоритм вчиться знаходити зв'язки між вхідними ознаками на цільовою змінною. Задачі для навчання з вчителем включають класифікацію та регресію. Задачею класифікації може бути, наприклад, визначення напрямку руху ціни активу: зростати чи спадати, тобто алгоритм навчається на розмічених часових рядах, позначених як "зростає" або "спадає". Задачею регресії може бути, наприклад, прогнозування ціни на актив через  $n$  періодів у майбутнє.

У навчанні без вчителя алгоритм навчається на немаркованих даних і повинен знайти закономірності або зв'язки в них. Кластеризація та вивчення правил асоціації

є поширеними завданнями в цій категорії. Так можна, наприклад, шукати аномальні відхилення ціни або обсягів активу за певний період часу [61].

Напівконтрольоване навчання поєднує в собі аспекти як навчання з вчителем, так і навчання без вчителя. Такий метод використовує невелику кількість розмічених даних разом із великим набором нерозмічених даних для підвищення точності навчання. Таким чином можна, наприклад, за допомогою невеликої кількості розмічених даних аномальних відхилень ціни та великої кількості нерозмічених даних прогнозувати загальну динаміку ринкових цін.

Навчання з підкріпленням передбачає навчання агента приймати послідовні рішення шляхом винагороди за бажані дії та покарання за небажані. Такі алгоритми широко використовуються в алгоритмічній торгівлі з метою відтворити процес прийняття рішень людиною [62].

Лінійна регресія – це алгоритм навчання з вчителем, який використовується для прогнозування безперервних значень на основі вхідних ознак [63]. Цей алгоритм моделює зв'язок між залежною змінною і однією або кількома незалежними змінними за допомогою лінійного рівняння (2.6):

$$y = wx + b, \quad (2.6)$$

де  $y$  – це залежна змінна,  $x$  – незалежна змінна (або предиктор),  $w$  – ваги, або коефіцієнти та  $b$  – вільний коефіцієнт.

Метод опорних векторів (Support Vector Machine, або ж SVM) [64] – це алгоритм навчання з вчителем, який використовується для завдань класифікації, регресії та виявлення аномалій. Він особливо дієвий у просторах великої розмірності та коли кількість вимірів перевищує кількість вибірок. SVM працює, знаходячи оптимальну гіперплощину, яка найкраще розділяє точки даних різних класів у просторі ознак. Ця гіперплощина розташовується відповідно до максимізації маржі (відстані між гіперплощиною та найближчими точками даних з обох класів, відомих як опорні вектори). Якщо дані лінійно розділені, SVM знаходить пряму гіперплощину. Якщо дані не розділяються лінійно, SVM може використати

перетворення (kernel trick), щоб перетворити дані у простір вищої розмірності, де вони стають лінійно роздільними. Математично гіперплощина визначається як (2.7):

$$w \cdot x + b = 0, \quad (2.7)$$

де  $w$  – вектор ваги (нормаль до гіперплощини),  $x$  – вектор ознак, а  $b$  – вільний коефіцієнт. Маржа максимізується шляхом мінімізації ваг.

К-найближчі сусіди (K-Nearest Neighbours, або ж KNN) – використовується як для завдань класифікації, так і для регресії [65]. KNN також відомий як алгоритм навчання на основі екземплярів. KNN зберігає дані навчання в пам'яті, обчислює відстані між новими точками даних та всіма точками в навчальному наборі, далі знаходить  $k$  найближчих точок (найближчих сусідів) і робить прогноз на основі класу більшості (класифікація) або середнього значення сусідніх значень (регресія).

Дерево рішень (Decision Tree, або ж DT) – це алгоритм навчання з вчителем, який використовується для завдань класифікації та регресії [66]. Він моделює дані за допомогою деревоподібної структури, де кожен внутрішній вузол представляє рішення на основі ознаки, кожна гілка представляє результат, а кожен листовий вузол представляє мітку класу (для класифікації) або безперервне значення (для регресії). Дерева рішень широко використовуються завдяки своїй простоті, інтерпретації та здатності обробляти числові, дискретні та бінарні значення. Мета алгоритму полягає в тому, щоб розділити дані таким чином, щоб максимізувати поділ різних класів (у класифікації) або мінімізувати дисперсію (у регресії). Критерієм для поділу можуть бути Gini та ентропія для задач класифікації, а також середня квадратична помилка для задач регресії. На рис. 2.2 зображено приклад класифікації відповідей на пряму розсилку листів.



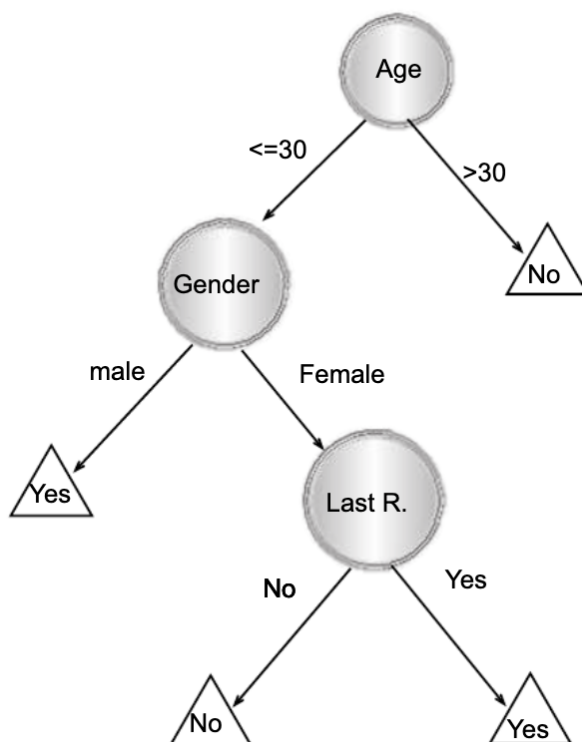


Рис. 2.2 – Приклад дерева рішень, що класифікує відповіді на пряму розсилку листів користувачам [66]

Випадковий ліс (Random Forest, або ж RF) – це алгоритм ансамблевого навчання, який використовується для завдань класифікації та регресії. Особливість Random Forest полягає в поєднанні кількох дерев рішень, що знижує тенденцію окремих дерев переоцінювати або недооцінювати дані [67]. Random Forest формує вибірки за допомогою статистичного бутстрепа із заміною для навчання кожного дерева та випадково вибирає підмножину ознак для кожного розбиття. Таким чином алгоритм зменшує дисперсію окремих дерев рішень і покращує процес узагальнення.

Гرادієнтний бустинг (Gradient Boosting Machine, або ж GBM) – це алгоритм ансамблевого навчання, який створює сильну прогностичну модель шляхом об'єднання прогнозів слабких моделей [68]. У більшості випадків ці слабкі моделі є деревами рішень. На відміну від таких алгоритмів, як Random Forest, які будують дерева незалежно один від одного, Gradient Boosting мінімізує функцію втрат шляхом послідовного додавання нових дерев до ланцюжка, які зосереджуються на похибках, зроблених попередніми деревами.

Штучна нейронна мережа (Artificial Neural Network, або ж ANN) [69] на рис 2.3 – це модель, натхненна структурою та функціонуванням людського мозку. Вона складається з шарів взаємопов'язаних вузлів (нейронів), які обробляють і перетворюють вхідні дані. ANN працює через мережу штучних нейронів, розташованих шарами:

- 1) вхідний шар: отримує необроблені дані (наприклад, зображення, текст, числові значення);
- 2) приховані шари: проміжні шари, на яких відбувається обчислення. Вони обробляють і формують ознаки з вхідних даних;
- 3) вихідний шар: генерує кінцевий результат (наприклад, значення класу або прогнозоване значення).

Навчання ANN включає:

- 1) пряме розповсюдження: дані передаються через мережу шар за шаром, а вихід обчислюється на основі поточних ваг нейронів та вільних коефіцієнтів;
- 2) функція витрат: порівнює результат прямого розповсюдження нейронної мережі із фактичними значеннями (ground truth) та вимірює похибку цієї різниці;
- 3) зворотне поширення та оптимізація: порахована похибка поширюється назад через мережу, визначаючи внесок кожного вузла в цю похибку. Після цього ваги корегують свої значення шляхом мінімізації цієї похибки.




Рис. 2.3 – Штучна нейронна мережа [69]

Типи ANN:

1) нейронні мережі прямого зв'язку (Feedforward Neural Network, або ж FNN) – прості мережі, де інформація рухається в одному напрямку (без циклів). Такий тип нейронної мережі може бути як одношаровим, так і багатошаровим. На рис. 2.4 зображено архітектуру нейронної мережі прямого зв'язку;




Рис. 2.4 – Нейронна мережа прямого зв'язку [69]

2) згорткові нейронні мережі (Convolution Neural Network, або ж CNN) – використовуються для розпізнавання та обробки зображень, аналізу часових рядів та сигналів. CNN чудово виділяють просторові характеристики (краї, текстури, візерунки) із зображень та аномальні значення часових рядів. На відміну від традиційних FNN, які обробляють вхідні функції незалежно, CNN зберігають просторові зв'язки та зменшують обчислювальну складність за допомогою таких методів, як “згортка” та “об’єднання”. CNN складається з кількох рівнів, призначених для поступового вилучення “функцій вищого рівня” з вхідних даних. Основною операцією в CNN є “згортка”, де невелика матриця (“ядро” або “фільтр”) ковзає по вхідній матриці та виділяє ознаки (наприклад, краї, текстури). Кожен фільтр створює “карту функцій”, висвітлюючи різні характеристики матриці. На рис. 2.5 зображено архітектуру згорткової нейронної мережі VGG16;




Рис. 2.5 – Згорткова нейронна мережа VGG16 [70]

3) рекурентні нейронні мережі (Recurrent Neural Network, або ж RNN) – призначені для послідовних даних [69]. На відміну від нейронних мереж прямого зв'язку і згорткових нейронних мереж, RNN зберігають пам'ять про послідовні закономірності попередніх входних даних, щоб навчатися з послідовностей. RNN зазвичай використовуються в таких завданнях, як обробка природної мови (Natural Language Processing, або ж NLP), прогнозування часових рядів (наприклад, прогнозування курсу акцій, прогнозування погоди), обробка аудіо (наприклад, розпізнавання мови, створення музики) та обробка відео (наприклад, розпізнавання дій). Основна ідея RNN полягає в тому, щоб мати зворотні зв'язки у вузлах мережі, які дозволяють інформації зберігатися упродовж багатьох ітерацій навчання. RNN складається з трьох ключових компонентів: вхід, прихований стан (пам'ять про попередні стани) та вихід;

4) нейронна мережа з довгою короткостроковою пам'яттю (Long short-term memory, або ж LSTM) [70] – спеціалізований RNN для довготривалих залежностей. Цей тип мережі призначений для вирішення проблеми зникнення градієнта (vanishing gradient), що перешкоджає стандартним RNN запам'ятовувати закономірності в послідовних даних упродовж навчання. Під час навчання глибоких RNN градієнти зменшуються, коли вони поширюються через велику кількість часових кроків, що ускладнює для мережі вивчення довгострокових закономірностей. Щоб розв'язати ці

проблеми, LSTM має “комірку пам’яті” та механізми “вентилювання”, які регулюють потік інформації. Існують вхідний, вихідний та вентиляції забування. Ці вентиляції реалізують із застосуванням логістичної функції для обчислення значень між 0 та 1. Для часткового дозволу або заборони плин інформації до або з цієї пам’яті застосовується множення на це значення. Наприклад, “вхідний вентиль” (input gate) керує мірою, до якої нове значення входить до пам’яті, “забувальний вентиль” (forget gate) керує мірою, до якої значення залишається в пам’яті, а “вихідний вентиль” (output gate) керує мірою, до якої значення в пам’яті використовується для обчислення активування виходу блоку. LSTM широко використовуються в тих же задачах, що й RNN, але мають більшу перевагу над останніми в “запам’ятовуванні” послідовностей;

5) генеративні змагальні мережі (Generative adversarial network, або ж GAN) – це тип моделі глибокого навчання, розробленої для генеративних завдань, тобто вона може створювати нові дані, схожі на заданий набір даних. GAN були представлені Ian Goodfellow та ін. у 2014 році [71] та зробили революцію в таких галузях, як створення зображень та синтетичних даних. GAN складаються з двох нейронних мереж, які конкурують одна з одною: генератор створює підроблені дані з випадкового шуму, дискримінатор намагається відрізнити справжні дані від підроблених. Такий змагальний процес навчання змушує генератора створювати більш реалістичні дані з часом, покращуючи якість створених зразків;

6) трансформер (Transformer) – це архітектура нейронних мереж, яка революціонізувало сферу обробки природної мови і з тих пір широко застосовувалося в багатьох областях, таких як генерація тексту, машинний переклад, розпізнавання мовлення та обробка зображень [72, 73]. На відміну від попередніх архітектур, таких як RNN чи LSTM, Transformer використовує механізм, відомий як самоувага (self-attention), для обробки послідовностей даних, що дозволяє їй точніше обробляти довгострокові залежності. Основні характеристики трансформерів:

- механізм уваги: фокусується на важливих частинах послідовностей, дозволяючи моделі вивчати контекстуальні зв’язки між сутностями в послідовності, незалежно від їх відстані;

- паралелізація: на відміну від мереж RNN, які обробляють дані послідовно, Transformers можуть обробляти всі елементи послідовності одночасно, що значно прискорює навчання;

- архітектура кодера-декодера: зазвичай використовується для таких завдань, як переклад, де вхідні дані обробляються кодувальником, а вихідні дані генеруються декодером.

K-Means – це один із найпоширеніших алгоритмів навчання без вчителя для задач кластеризації. Мета кластеризації полягає в тому, щоб розділити набір точок даних на окремі групи або кластери, щоб точки даних в одному кластері були більш схожі одна на одну, ніж на точки в інших кластерах. K-Means працює шляхом групування даних у K кластерів, де K – це заздалегідь визначена кількість кластерів [74]. Ключова ідея алгоритму K-Means полягає в мінімізації внутрішньої кластерної дисперсії, яка є сумою квадратів відстаней між кожною точкою даних і центроїдом (середнім значенням) кластера, якому вона призначена.

Ієрархічна кластеризація (Hierarchical clustering) – це клас алгоритмів навчання без вчителя, які використовуються для групування точок даних у кластери на основі їх подібності. На відміну від кластеризації K-Means, де кількість кластерів потрібно вказати заздалегідь, ієрархічна кластеризація створює ієрархію кластерів і не вимагає попереднього визначення кількості кластерів [75]. Ієрархічна кластеризація може бути розбита на два основних типи: агломеративна (знизу вгору) ієрархічна кластеризація та роздільна (зверху вниз) ієрархічна кластеризація. Хоча агломеративний підхід є найбільш поширеним, обидва методи зрештою створюють деревоподібну структуру, яка називається дендрограмою, яка представляє вкладене групування точок даних.

### **2.3.2 Застосування машинного навчання в задачах прогнозування ринкових тенденцій**

Пател та ін. [76] оцінили точність чотирьох моделей прогнозування: штучних нейронних мереж (ANN), методу опорних векторів (SVM), випадкового лісу та простої моделі Баєса у прогнозуванні динаміки акцій та індексів на індійських ринках.

Модель Баєса – це ймовірнісна модель, заснована на теоремі Баєса, яка описує, як оновити переконання за наявності нових доказів. Результати показують, що випадковий ліс найкраще працює з безперервними параметрами. Також застосування штучних нейронних мереж досліджено в [77], [78] та [79] зі схожою точністю.

Застосування LSTM та RNN досліджено в задачах прогнозування цін активів на фондових ринках у [80, 81, 82, 83, 84]. Досліджено Баєсівську регуляризовану штучну нейронну мережу для прогнозування щоденних цін закриття акцій [85]. Такий тип нейронної мережі застосовує методи баєсівського висновку та регуляризації для покращення узагальнення та запобігання перенавчанню моделі.

Представлено архітектуру GAN для прогнозування ціни закриття акцій, яка поєднує LSTM як генератор для моделювання розподілу даних про акції та MLP як дискримінатор для розрізнення реальних і згенерованих даних. Експериментальні результати на S&P 500 та інших акціях демонструють, що запропонований GAN перевершує традиційні моделі машинного та глибокого навчання у прогнозуванні щоденних цін закриття [86].

Досліджено новий підхід глибокого навчання, який поєднує Paragraph Vector і LSTM для прогнозування фінансових часових рядів шляхом інтеграції числових даних і розподілених представлень текстової інформації з новинних статей [87]. Перевірена на даних 50 компаній Токійської фондової біржі, модель точно враховує впливи минулих подій на ціни на біржі в момент відкриття. Також представлено Extreme Learning Machine (ELM) для прогнозування руху цін на акції шляхом одночасного аналізу ринкових даних і новин. Експериментальні результати показують, що ELM перевершує інші моделі, такі як SVM і BP-NN [88]. ELM – це тип однорівневої нейронної мережі прямого зв'язку, розробленої для швидкого навчання. На відміну від традиційних нейронних мереж, ELM не вимагає ітераційного налаштування вагових коефіцієнтів за допомогою зворотного поширення. Натомість він випадковим чином ініціалізує вагові коефіцієнти прихованого шару та аналітично обчислює вихідні ваги за допомогою методу найменших квадратів.

Запропоновано використовувати Open Information Extraction (Open IE) для вилучення структурованих подій із новинних статей для прогнозування руху цін на акції [89].

Аналіз настроїв (sentiment analysis) поєднано із SVM для прогнозування руху цін на акції з урахуванням ефекту дня тижня. Аналіз настроїв – це техніка обробки природної мови, яка використовується для визначення емоційного тону, що стоїть за фрагментом тексту. Це допомагає класифікувати текст як позитивний, негативний або нейтральний, а також може виявляти такі емоції, як щастя, гнів або смуток. Модель досягає очікуваної точності у прогнозуванні напрямку руху індексу SSE 50, показуючи, що дані про настрої можуть надати цінну інформацію для прогнозування тенденцій фондового ринку [90]. Також метод опорних векторів досліджено в [91].

Застосовано алгоритм KNN і нелінійну регресію для прогнозування цін на акції шести великих компаній на фондовій біржі Йорданії [92]. Розроблено еволюційну частково зв'язану нейронну мережу (EPCNN) [93], застосовано ансамбль з алгоритмів випадкового лісу, екстремального градієнтного бустингу (Extreme Gradient Boost, або ж XGBoost) та LSTM мережі [94] і легкого градієнтного бустингу (Light Gradient-Boosting Machine, або ж LightGBM) [95] для прогнозуванні ринкових тенденцій.

Досліджено застосування алгоритмів машинного навчання на ринку криптовалют для прогнозування мінімальної, максимальної цін [96], тенденцій ринку [97, 98], аналізу часових рядів [99]. Розроблено методологію прогнозування ціни на Біткоїн за використанням цін інших криптовалют [100]. Досліджено прогнозування волатильності криптовалют [101, 102, 103], з врахуванням ордерів на купівлю та продаж [104] та марковських ланцюгів [105].

Алгоритми глибокого навчання були застосовані для прогнозування ринкових тенденцій ринку криптовалют [106, 107, 108], у тому числі LSTM [109, 110], ансамблі моделей [111]. Застосовано авторегресійну ковзну середню [112] та порівняно результати з LSTM [113]. Модель авторегресійного ковзного середнього (Autoregressive Moving Average, або ж ARMA) – це модель прогнозування часових рядів, яка поєднує два компоненти: компонент авторегресії (autoregression, або ж AR), що використовує минулі значення для прогнозування майбутніх значень та



компонент ковзного середнього (moving average, або ж МА), що використовує попередні похибки прогнозу для покращення наступних прогнозів. Використано данні блокчейну (on-chain data) з алгоритмами глибокого навчання для прогнозування цін на криптовалюти [114].

Temporal Fusion Transformer (TFT) створено для точного та мультигоризонтного прогнозування часових рядів, забезпечуючи при цьому можливість інтерпретації часової динаміки [115]. TFT поєднує в собі сильні сторони трансформерів (для захоплення довгострокових залежностей) і рекурентних нейронних мереж (для послідовного моделювання), а також інтегруючи механізми уваги для інтерпретації.

Informer – це архітектура глибокого навчання, спеціально розроблена для прогнозування довгих часових рядів. Вона покращує стандартні трансформери, розв'язуючи такі проблеми, як сильне використання оперативної пам'яті та довгий час навчання, а це робить архітектуру набагато швидшою для обробки великих часових рядів. Тобто Informer розв'язує проблему квадратичної складності часу при роботі алгоритму та обмежень кодера-декодера, що робить мережу помітно швидшою за аналогічні архітектури [116].

Архітектура Fredformer (Frequency Debaised Transformer), спеціально розроблена для покращення прогнозування часових рядів шляхом розв'язання проблеми частотного зміщення. Традиційні архітектури трансформерів часто виявляють низькочастотні компоненти в даних часових рядів, потенційно пропускаючи критичні високочастотні компоненти. Fredformer пом'якшує цю помилку, забезпечуючи збалансоване навчання в різних частотних діапазонах, що веде до більш точного та надійного прогнозування [117].

PRformer – спроба поєднати Pyramid RNN (PRE) з архітектурою Трансформер для розв'язання обмежень позиційного векторного простору (embedding) у часових рядах. Результати експериментів демонструють високу точність на реальних наборах даних [118].

Досліджується застосування архітектури Трансформер для прогнозування індексів фондового ринку включно з CSI 300, S&P 500, Hang Seng Index і Nikkei 225.

Результати показують, що Трансформер значно перевершує традиційні методи прогнозування [119]. В іншій роботі Трансформер перевершує контрольні моделі, досягаючи нижчого RMSE 0.96 порівняно з 1.58 у моделі LSTM [120]. Досліджено прогнозування цін акцій на Dhaka Stock Exchange (DSE), де результати перевершують еталонний тест ARIMA з точки зору середньоквадратичної помилки для більшості акцій [121]. ARIMA (Autoregressive Integrated Moving Average) – широко використовувана статистична модель для прогнозування часових рядів. Це розширення моделі ARMA, розробленої для обробки нестационарних часових рядів шляхом включення диференціювання значень в обчислення.

Архітектуру Трансформер застосовували й у прогнозуванні цін криптовалют. Так, наприклад, прогнозування ціни Dogecoin на годинному таймфреймі [122]. Досліджуються Трансформер та LSTM, а також мультифрактальний аналіз коливань, щоб передбачити ціни на Ethereum, Binance Coin і Bitcoin [123]. Запропоновано Deep Learning-Enhanced Temporal Fusion Transformer (ADE-TFT) для покращення прогнозу ціни Біткоїна. Результати демонструють високу точність прогнозування за метриками похибок MAPE, MSE і RMSE. Автори підкреслюють важливість використання різних стратегій нормалізації для кращої точності [124].

Досліджено застосування глибокого навчання у задачах прогнозування ринкових тенденцій з використанням даних книги лімітних заявок (LOB) за допомогою згорткових та LSTM шарів. Модель демонструє стабільну точність прогнозування [125]. Запропоновано мультигоризонтну модель прогнозування, яка використовує специфічну згорткову мережу (Temporal Convolution Network) для кращого охоплення залежностей на великій відстані та зв'язків між функціями у даних LOB [126]. Temporal Convolution Network (або Часова Згорткова Мережа) – це архітектура нейронної мережі, розроблена для моделювання послідовностей та прогнозування часових рядів. На відміну від рекурентних моделей, таких як LSTM, TCN використовує лише одновимірні згорткові шари для захоплення часових залежностей, що робить його швидшим і більш масштабованим, ніж традиційні рекурентні мережі.

Представлено модель ViT-LOB, легку модель глибокого навчання, що працює винятково за архітектурою Трансформера, призначену для прогнозування тенденцій цін на акції з використанням даних LOB. Результати тестування на наборі даних FI-2010 демонструють, що ViT-LOB скорочує час інференсу на 54% і споживання оперативної пам'яті більш ніж на 90%, водночас перевершуючи найсучасніші методи в контексті точності прогнозування [127]. В Таблиці 2.1 представлено порівняльний аналіз методів машинного навчання в задачах прогнозування динаміки криптовалютного ринку.

Таблиця 2.1

Порівняльний аналіз методів машинного навчання в задачах прогнозування динаміки криптовалютного ринку

Клас методів	Моделі	Переваги	Недоліки
Класичне ML	SVM, Випадковий ліс, KNN	Прості, швидкі, універсальні	Часто менш точні за алгоритми глибокого навчання, Трансформери
Базові нейромережі	ANN, Баєсівська ANN, ELM	Менша потреба в конструюванні ознак	Чутливі до гіперпараметрів, схильні до перенавчання
Рекурентні мережі (RNN)	LSTM, RNN	Здатні виявляти часові закономірності	Повільні, а також менш точні порівняно з Трансформерами
Аналіз тексту (NLP)	Аналіз настроїв	Визначає емоційний тон новин	Дані про настрої не є самодостатніми для точного прогнозування цін
Гібриди та ансамблі	GAN, XGBoost, LightGBM	Часто більш точні за традиційне глибоке навчання	Мають вищу потребу в конструюванні ознак
Авторегресійні моделі	AR, ARIMA	Прості та швидкі моделі	Поступаються в точності більшості моделям
Згорткові мережі	CNN, TCN	Просторовий аналіз часових рядів	Специфічні під (LOB)
Трансформери	TFT, Informer, Fredformer	Точні, масштабовані	Вимагають велику кількість даних та часу для тренування

## 2.4 Причинно-наслідковий аналіз

Причинно-наслідковий аналіз – це набір технік, які використовуються для пошуку та розуміння зав'язків між змінними та подіями в системі шляхом визначення того, чи зміни однієї змінної викликають зміни іншої. Цей аналіз має на меті пояснити, чому виникають певні зв'язки, і розкрити основні механізми, які керують цими зв'язками, а не просто виявити кореляції між змінними.

Причинно-наслідковий аналіз активно використовується для пошуку факторів, що впливають на ціну біткоїна, щоб допомогти інвесторам приймати кращі інвестиційні рішення [128].

Для проведення причинно-наслідкового аналізу визначають три загальні категорії змінних:

- 1) змінна впливу (Treatment) – змінна маніпулюється в експерименті, щоб спостерігати її вплив на залежну змінну;
- 2) результат (Outcome) – змінна, що вимірюється для визначення впливу змінної впливу;
- 3) змішуючі змінні (Confounding variables) – не є основним предметом дослідження, але вони можуть впливати на зв'язок між незалежними та залежними змінними.

Для вимірювання причинного ефекту використовуються такі показники:

- 1) середній ефект впливу (Average Treatment Effect, або ATE) – це середня різниця в змінній результаті між групою, на яку впливають (treated), і групою, на яку не впливають (control);
- 2) середній ефект впливу на тих, на кого впливали (Average Treatment Effect on the Treated, або ATT) – вимірює середню різницю в змінній результаті для тих, на кого впливали, порівняно з результатами, які були б, якби на них не впливали;
- 3) середній ефект впливу на контрольну групу (Average Treatment Effect on the Control, або ATC) – вимірює середню різницю в змінній результаті для учасників контрольної групи порівняно з результатами, якби на них впливали.

Для оцінювання причинно-наслідкового ефекту було використано три методи:

1) propensity score matching (PSM) – використовувався для створення збалансованої групи порівняння шляхом зіставлення treated і not treated одиниць на основі їхніх оціночних ймовірностей отримання впливу (балів схильності) [129];

2) propensity score stratification (PSS) – це метод, який поділяє вибірку на страти з використанням оцінених оцінок схильності, а потім аналізує результати в межах кожного стану [130];

3) Double ML (DML) – цей метод поєднує в собі сильні сторони машинного навчання та статистичних методів для забезпечення узгоджених оцінок причинно-наслідкових ефектів [131].

Для перевірки валідності причинно-наслідкових моделей було використано три тести на спростування: random common cause (RCC), placebo treatment refuter (PTR) і data subset refuter (DSR) [132].

Підсумовуючи, за допомогою причинно-наслідкового аналізу ми можемо зрозуміти причинно-наслідкові зв'язки між змінними чи подіями як у різних галузях [133], так і на криптовалютному ринку [134, 135]. Це допомагає дослідникам і аналітикам приймати обґрунтовані рішення, прогнозувати події та розуміти механізми, що лежать в їх основі.

## **Висновки до розділу 2**

Еконофізика дозволяє застосовувати методи фізики до фінансових ринків, включно зі статистичною механікою, теорію хаосу, фрактальним аналізом і концепцією ентропії. Механістичний підхід використовує аналогії з класичної механіки, де обсяг транзакцій розглядається як маса, а зміна ціни як швидкість активу. Використання механістичного моментуму дозволяє покращити прогнозування цінових тенденцій за допомогою ковзних середніх.

Машинне навчання демонструє очікувану точність у прогнозуванні ринкових тенденцій, значно перевершуючи традиційні статистичні методи. Основні методи, що застосовуються в аналізі фінансових ринків – це класифікаційні та регресійні алгоритми такі як: метод опорних векторів (SVM), випадковий ліс (RF), градієнтний

бустинг (GBM, XGBoost, LightGBM), нейронні мережі (LSTM, RNN, CNN, GAN, Transformer) та ансамблеві алгоритми.

Використання нейронних мереж, зокрема LSTM та Transformer, дозволяє точно прогнозувати ціни акцій та криптовалют, враховуючи як історичні часові ряди, так і текстові дані (аналіз новин, настроїв ринку). Також прогнозування цін криптовалют здійснюється з використанням моделей ARMA та ARIMA. Особливий інтерес становлять архітектури трансформерів, такі як Temporal Fusion Transformer (TFT) та Informer, що забезпечують високу точність прогнозування.

Таким чином, сформовано базу для подальших досліджень та створення нових комбінованих методів, що поєднують аналіз обсягів (механістичний підхід) та передові алгоритми машинного навчання для підвищення точності прогнозування ринкових змін в умовах високої волатильності та нестаціонарності криптовалютного ринку.

### РОЗДІЛ 3. РОЗРОБКА МЕТОДІВ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ДИНАМІКИ РИНКУ КРИПТОВАЛЮТ

#### 3.1 Удосконалення методу механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці

Ринковий ордер – це тип ордеру на негайну покупку або продаж товарів, активів тощо за найкращою доступною ціною. Цей тип ордеру гарантує виконання, але не точну ціну, оскільки ціни можуть швидко змінюватися. Ринкові ордери важливі для учасників ринку, які віддають перевагу швидкості над контролем ціни. Ринкові ордери, як і лімітні заявки, відіграють фундаментальну роль у ринковій мікроструктурі, оскільки сприяють формуванню ціни.

Ринкові ордери зазвичай відіграють роль “рушія” цін, в той час як лімітні заявки сповільнюють рух цін. Ринкові покупки створюють попит на актив (або ж дефіцит), змушуючи ціни зростати, а ринкові продажі створюють пропозицію (або ж профіцит) змушуючи ціни спадати. Застосування ринкових обсягів покупок та продажів дає глибше розуміння ринкової динаміки. Оскільки це допомагає визначити зміни в попиті та пропозиції, сигналізуючи про потенційні цінові тенденції або розвороти. Якщо ж агресивні ринкові купівлі перевищать ліквідність на стороні продажу, ціни можуть зростати, тоді як надмірні ринкові продажі можуть призвести до зниження цін. Також, непропорційно великий ринковий обсяг по відношенню до руху ціни може свідчити про прихований лімітний обсяг, який поглинає ліквідність.

У формулі механістичного імпульсу (2.1) ринкові обсяги  $V_t$  – це сума ринкових покупок та продажів. Вдосконалення механістичного імпульсу полягає в незалежному використанні обсягів:

- 1) ринкових покупок;
- 2) ринкових продажів;
- 3) різницею між ринковими покупками та продажами.

Розглянемо  $V_{buy,t}$  як обсяг ринкових покупок активу за ціною  $x(t)$  у момент часу  $t$ . Узагальнений імпульс ринкових покупок  $\tilde{R}_{\tau,buy}$  за інтервал часу  $\tau$  можна визначити через (3.1):

$$\tilde{R}_{\tau,buy}(t) = \frac{V_{buy,t}}{\langle V_{buy,t} \rangle_{\tau}} \cdot \frac{x(t) - x(t-\tau)}{\tau}, \quad t = \tau + 1, \dots, N, \quad (3.1)$$

де  $V_{buy,t}$  – це обсяг покупок у момент часу  $t$ , сума ринкових покупок за інтервал  $\tau$  це  $\langle V_{buy,t} \rangle_{\tau} \tau = \sum_{i=1}^{\tau} V_{buy}(i)$ , а середня швидкість зміни ціни за інтервал часу  $\tau$  це  $\frac{x(t) - x(t-\tau)}{\tau}$ .

Аналогічно розглянемо  $V_{sell,t}$  як обсяг ринкових продажів активу за ціною  $x(t)$  у момент часу  $t$ . Узагальнений імпульс ринкових продажів  $\tilde{R}_{\tau,sell}$  за інтервал часу  $\tau$  можна визначити через (3.2):

$$\tilde{R}_{\tau,sell}(t) = \frac{V_{sell,t}}{\langle V_{sell,t} \rangle_{\tau}} \cdot \frac{x(t) - x(t-\tau)}{\tau}, \quad t = \tau + 1, \dots, N, \quad (3.2)$$

де  $V_{sell,t}$  – це обсяг продажів у момент часу  $t$ , сума ринкових продажів за інтервал  $\tau$  це  $\langle V_{sell,t} \rangle_{\tau} \tau = \sum_{i=1}^{\tau} V_{sell}(i)$ , а середня швидкість зміни ціни за інтервал часу  $\tau$  це  $\frac{x(t) - x(t-\tau)}{\tau}$ .

Розглянемо  $VD_t$  як абсолютну різницю в обсягах покупок та продажів активу за ціною  $x(t)$  у момент часу  $t$ . Узагальнений імпульс різниці (або ж дельти) ринкових обсягів  $\tilde{R}_{\tau,VD}$  за інтервал часу  $\tau$  можна визначити через (3.3):

$$\tilde{R}_{\tau,VD}(t) = \frac{VD_t}{\langle VD_t \rangle_{\tau}} \cdot \frac{x(t) - x(t-\tau)}{\tau}, \quad t = \tau + 1, \dots, N, \quad (3.3)$$

де  $VD_t$  – це абсолютна різниця обсягів покупок та продажів  $|V_{buy,t} - V_{sell,t}|$  у момент часу  $t$ , сума абсолютних різниць ринкових обсягів покупок та продажів за інтервал  $\tau$  це  $\langle VD_t \rangle_{\tau} \tau = \sum_{i=1}^{\tau} VD(i)$ , а середня швидкість зміни ціни за інтервал часу  $\tau$  це  $\frac{x(t) - x(t-\tau)}{\tau}$ .

Необхідно зауважити, що для  $\tilde{R}_{\tau,VD}$  обчислюється абсолютна різниця між обсягами покупок та продажів, оскільки за певних умов ця різниця може набувати від'ємних значень, що призводить до проблем інтерпретації узагальненого імпульсу.



Узагальнений імпульс – це тип “імпульсу” за аналогією в екофізиці, подібний до механічної концепції  $p = mv$  (імпульс = маса  $\times$  швидкість).

- Якщо  $VD_t > 0$  і  $\frac{x(t) - x(t-\tau)}{\tau} > 0$ , тоді  $\tilde{R}_{\tau,VD} > 0$ , тобто імпульс дельти обсягів позитивний, що означає домінацію ринкових покупок, які підтримують підвищення ціни.

- Якщо  $VD_t < 0$  і  $\frac{x(t) - x(t-\tau)}{\tau} < 0$ , тоді  $\tilde{R}_{\tau,VD} > 0$ , тобто імпульс дельти обсягів негативний, що означає домінацію ринкових продажів, які підтримують зниження ціни.

- Однак, якщо  $VD_t < 0$ , але  $\frac{x(t) - x(t-\tau)}{\tau} > 0$ , тоді  $\tilde{R}_{\tau,VD} < 0$ , що свідчить про те, що, незважаючи на продаж, ціна зростає, а імпульс негативний. Аналогічно, якщо  $VD_t > 0$ , але  $\frac{x(t) - x(t-\tau)}{\tau} < 0$ , тоді  $\tilde{R}_{\tau,VD} < 0$ , що свідчить про те, що, незважаючи на покупки, ціна спадає, а імпульс знову негативний.

Тому узагальнений імпульс може набувати однакових значень в абсолютно різних ситуаціях, що ускладнює інтерпретацію та застосування. Використання абсолютної різниці обсягів покупок та продажів в узагальненому імпульсі дає чітку інформацію про дисбаланс у обсягах, який призводить до зростання або ж спадання ціни. Однак, для розуміння які саме обсяги домінують, а які ні – потрібно звертати увагу на інші показники, такі як дельта ринкових обсягів або ж порівнювати динаміку зміни імпульсів ринкових покупок та ринкових продажів.

На рис. 3.1 зображено ціну (Price), обсяги (Volume), різницю між обсягами покупок та продажів (Volume Delta), узагальнений імпульс сумарних обсягів (GMI Volume), узагальнений імпульс обсягів покупок (GMI Volume Buy), узагальнений імпульс обсягів продажів (GMI Volume Sell) та узагальнений імпульс абсолютної різниці обсягів покупок та продажів (GMI Volume Delta Abs) на даних торгової пари BTC/USDT.



Рис. 3.1 – Імпульси ринкових обсягів торгової пари BTC/USDT

Можна побачити, що імпульси сумарних обсягів, покупок та продажів доволі сильно збігаються і мають лише невеликі відмінності в локальних максимумах та мінімумах, де сильно збільшується обсяги торгів. Тому ми можемо побачити більші абсолютні значення імпульсу в тих місцях, де відповідні йому ринкові обсяги покупок або продажів домінують.

У випадку з імпульсом дельти ринкових обсягів значення в локальних екстремумах більш помітні та зберігають напрямок відповідно до концепту механістичного підходу навіть тоді, коли значення дельти обсягів негативне.

На рис. 3.2 можна побачити узагальнену схему вдосконаленого методу механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці.

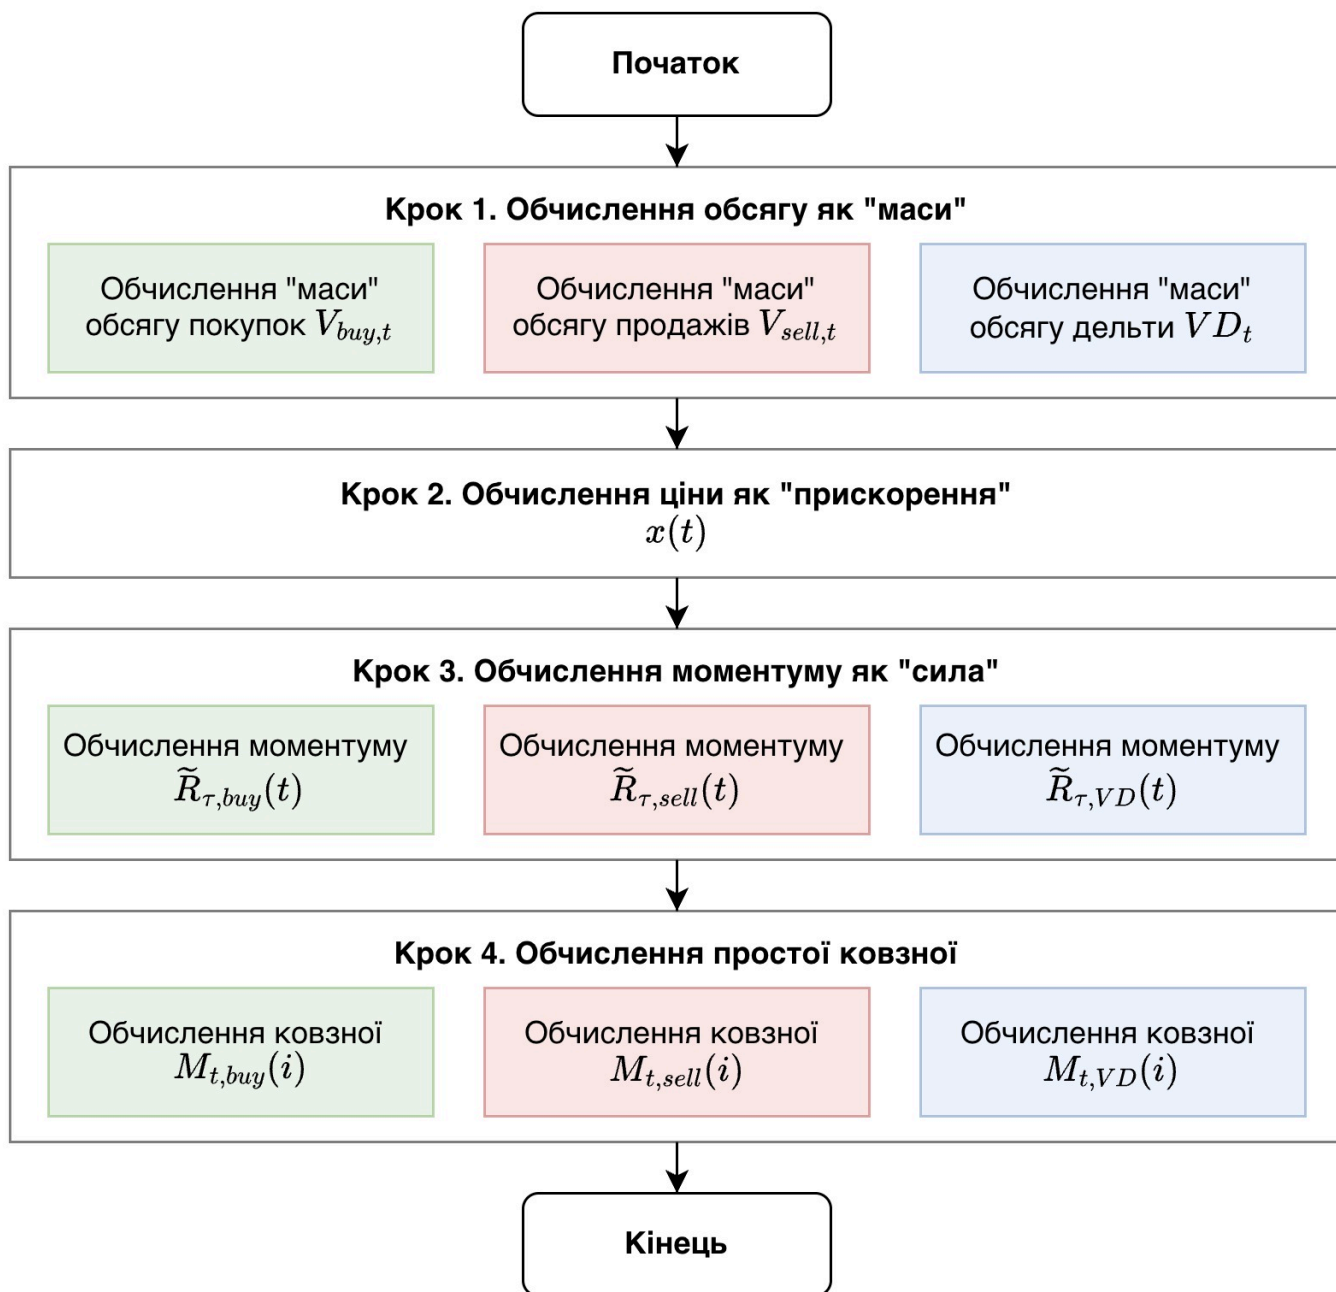


Рис. 3.2 – Схема вдосконаленого методу механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці

### 3.2 Розробка показника поглинання імпульсу (Momentum Absorption Score, MAS)

Імпульс у контексті фінансових ринків означає швидкість зміни ціни активу впродовж заданого інтервалу. Це важливий аспект технічного аналізу, коли торговці часто використовують індикатори імпульсу для оцінки потенціалу майбутніх коливань цін. Імпульс зазвичай розглядається як міра сили або слабкості певної цінової тенденції. Загальне правило моментум-торгівлі полягає в тому, що активи, які переживають сильний імпульс – чи то висхідний, чи то спадний – ймовірно, деякий час продовжуватимуть рухатися в тому ж напрямі.

Індикатор узагальненого імпульсу застосовує фізичний підхід до аналізу ринку: обчислює імпульс активу шляхом множення обсягу торгів на зміну в ціні упродовж певного періоду часу (2.1). Це вказує на те, наскільки значними є зміни ціни, коли вони супроводжуються великими обсягами торгівлі. У механіці взаємозв'язок між масою, прискоренням і силою зрозумілий: об'єкту з великою масою потрібна більша сила, щоб досягти того ж прискорення, що й об'єкт з меншою масою. Подібним чином на фінансових ринках актив із більшим обсягом торгів (подібно до більшої маси) відчуватиме більш значні зміни ціни (подібно до прискорення) у відповідь на ринкові події. Чим більший обсяг торгів, тим більша ймовірність того, що зміни ціни матимуть вплив.

На рис. 3.3 зображено метод механістичного аналізу (Generalized Momentum Indicator, або ж GMI), а також зміна ціни за визначений період (Price Difference) та відношення поточного обсягу до суми обсягів (Volume Ratio) за цей же період. Можна побачити, що індикатор має найвищі значення (тобто найсильніші імпульси зростання), коли зміни в ціні та співвідношення обсягів найбільші – тобто поточний обсяг помітно більший, аніж попередні за визначений період. Аналогічно для найсильніших імпульсів падіння показник набуває мінімальних значень при великих обсягах, але негативних змін у цінах. Значення показника близькі до нуля тоді, коли відношення обсягів менше 0.5 і зміни в цінах наближені до нуля. У таких випадках імпульс активу слабкий, що може свідчити про слабкий інтерес учасників ринку до активу.




Рис. 3.3 – Метод механістичного аналізу сумарних обсягів

Отже, аномальні значення індикатора узагальненого імпульсу вказують на сильну ринкову активність, тобто коли збільшується волатильність та обсяги торгів. Такі ситуації вказують на активність, яка вже сталася, а учасники ринку сподіваються на продовження імпульсу і тому можуть відкрити довгі угоди на покупку (long) або ж відповідно короткі на продаж (short).

А чи можливо виявити ситуації, коли ціна ще не почала свій активний рух, але вже з'явилися ознаки, які можуть призвести до імпульсу? Відкрити угоду в момент низької волатильності, а закрити під час високої – це може збільшити прибутковість угоди. Оскільки відкрити позицію на покупку, коли ціна сильно зросла, означає недоотримати прибуток від того, якщо б позиція була відкрита перед імпульсом.

Ідея показника поглинання імпульсу (Momentum Absorption Score, або ж MAS) полягає у тому, щоб знаходити такі ситуації, коли відносно великі обсяги були поглинуті учасниками ринку, але внаслідок цього ціна не змінилася значуще. На рис. 3.4 зображено випадок, коли один з барів ринкових обсягів покупок (зелений колір) помітно вищий за декілька останніх барів, а діапазон ціни від мінімального до максимального значень (червона свічка) дуже низький у порівнянні з попередніми записами. Відкрити угоду на покупку за поточною ціною, а отже перед наступною імпульсною ціною свічкою, може дати додатковий прибуток у порівнянні з тим, якщо купити актив після імпульсу.



Рис. 3.4 – Дельта ринкових обсягів та волатильність ціни

Розглянемо різницю між максимальною та мінімальною цінами за певний інтервал як (3.4). Необхідно зазначити, що інтервал це певний період у часі, який можна зобразити як одну цінову свічку, яка має 4 параметри: ціна відкриття, найвища ціна, найнижча ціна та ціна закриття. Надалі в усіх формулах будуть використовуватися визначення інтервалів як такі цінові свічки (точки на часовому ряді).

$$HL_t = H_t - L_t, \quad (3.4)$$

де  $H_t$  – це найвища ціна за інтервал  $t$ , а  $L_t$  – найнижча ціна за інтервал  $t$ .

Z-показник (z-score) використано для розрахунку наскільки різниця між максимальною та мінімальною цінами  $HL_t$  за інтервал  $t$  відхиляється від аналогічних різниць за останні  $w$  інтервалів (3.5).

$$Z_{HL_t} = \frac{HL_t - \mu_{HL,t}}{\sigma_{HL,t}}, \quad (3.5)$$

де  $\mu_{HL,t}$  – це середнє значення  $HL_t$  за останні  $w$  інтервалів (3.6), а  $\sigma_{HL,t}$  – стандартне відхилення  $HL_t$  за останні  $w$  інтервалів (3.7).

$$\mu_{HL,t} = \frac{1}{w} \sum_{i=t-w+1}^t HL_i, \quad (3.6)$$

де  $w$  – це період за який обчислюється середнє значення інтервалів  $t$ .

$$\sigma_{HL,t} = \sqrt{\frac{1}{w} \sum_{i=t-w+1}^t (HL_i - \mu_{HL,t})^2}, \quad (3.7)$$

де  $w$  – це період за який обчислюється стандартне відхилення інтервалів  $t$ .

Процентиль (percentile) 25% використовується для визначення аномально низької різниці між максимальною та мінімальною ціною у порівнянні з аналогічними різницями цін за останні  $w$  інтервалів (3.8):

$$P_\alpha(HL_t) = P_\alpha(HL_{t-w+1}, HL_{t-w+2}, \dots, HL_t), \quad (3.8)$$

де  $P_\alpha$  – це функція процентиля зі значенням  $\alpha = 25$ , яка повертає процентиль  $HL_t$  в моменті  $t$  за період  $w$ .

Z-показник (z-score), аналогічно до  $Z_{HL_t}$ , використано для розрахунку аномальності ринкових обсягів  $V$  в час  $t$  за останні  $w$  інтервалів (3.9):

$$Z_{V_t} = \frac{V_t - \mu_{V,t}}{\sigma_{V,t}}, \quad (3.9)$$

де  $\mu_{V,t}$  – це середнє значення  $V_t$  за останні  $w$  інтервалів (3.10), а  $\sigma_{V,t}$  – стандартне відхилення  $V_t$  за останні  $w$  інтервалів (3.11).

$$\mu_{V,t} = \frac{1}{w} \sum_{i=t-w+1}^t V_i, \quad (3.10)$$

де  $w$  – це період за який обчислюється середнє значення інтервалів  $t$ .

$$\sigma_{V,t} = \sqrt{\frac{1}{w} \sum_{i=t-w+1}^t (V_i - \mu_{V,t})^2}, \quad (3.11)$$

де  $w$  – це період за який обчислюється стандартне відхилення інтервалів  $t$ .

Процентиль (percentile) 75% використовується для визначення аномально великого обсягу у порівнянні з аналогічними обсягами за останні  $w$  інтервалів (3.12).

$$P_{\alpha}(V_t) = P_{\alpha}(V_{t-w+1}, V_{t-w+2}, \dots, V_t), \quad (3.12)$$

де  $P_{\alpha}$  – це функція процентиля зі значенням  $\alpha = 75$ , яка повертає процентиль  $V_t$  в момент  $t$  за період  $w$ .

Для визначення ситуацій, коли відносно великі обсяги були поглинуті учасниками ринку, але внаслідок цього ціна не змінилася значуще, необхідно виконати дві умови:

- умова перша:  $Z$ -показник різниці між максимальною та мінімальною ціною в момент  $t$  має бути меншим, ніж процентиль 25%  $Z$ -показників аналогічних різниць за період  $w$  (3.13);

$$Z_{HL_t} < P_{\alpha}(HL_t), \quad (3.13)$$

- умова друга:  $Z$ -показник ринкових обсягів в момент  $t$  має бути більшим, ніж процентиль 75%  $Z$ -показників аналогічних ринкових обсягів за період  $w$  (3.14).

$$Z_{V_t} > P_{\alpha}(V_t), \quad (3.14)$$

Виконання цих двох умов і формує показник поглинання імпульсу (3.15).

$$MAS_{V,t} = (Z_{HL_t} < P_{\alpha}(HL_t)) \wedge (Z_{V_t} > P_{\alpha}(V_t)), \quad (3.15)$$

де  $MAS_{V,t}$  – це показник поглинання імпульсу сумарних ринкових обсягів  $V_t$ .

Показники поглинання імпульсу різниці ринкових обсягів (Volume Delta) та балансу ринкових обсягів (Volume Balance) відрізняються від показника поглинання сумарних ринкових обсягів.

Для різниці ринкових обсягів покупок формула наступна (3.16):

$$MAS_{buy\ VD,t} = (Z_{HL_t} < P_{\alpha}(HL_t)) \wedge (Z_{VD_t} > P_{\alpha}(VD_t)), \quad (3.16)$$

де  $Z_{VD_t}$  – це  $z$ -показник різниці ринкових обсягів, а  $P_{\alpha}(VD_t)$  – це верхня межа розподілу  $VD_t$  у момент  $t$  за період  $w$  зі значенням  $\alpha = 75$ . Відмінність від (3.15) у тому, що замість сумарних обсягів  $V_t$  використовується різниця обсягів  $VD_t$ .



Для різниці ринкових обсягів продажів формула наступна (3.17):

$$MAS_{sell\ VD,t} = (Z_{HL_t} < P_\alpha(HL_t)) \wedge (Z_{VD_t} < P_\alpha(VD_t)), \quad (3.17)$$

де  $Z_{VD_t}$  – це z-показник різниці ринкових обсягів, а  $P_\alpha(VD_t)$  – це нижня межа розподілу  $VD_t$  у момент  $t$  за період  $w$  зі значенням  $\alpha = 25$ . Відмінність від (3.16) у тому, що  $\alpha = 25$  (замість  $\alpha = 75$ ), а  $Z_{VD_t}$  має бути нижчим за  $P_\alpha(VD_t)$ .

Для балансу ринкових обсягів покупок формула наступна (3.18):

$$MAS_{buy\ VB,t} = (Z_{HL_t} < P_\alpha(HL_t)) \wedge (Z_{VB_t} > P_\alpha(VB_t)), \quad (3.18)$$

де  $Z_{VB_t}$  – це z-показник балансу ринкових обсягів, а  $P_\alpha(VB_t)$  – це верхня межа розподілу  $VB_t$  у момент  $t$  за період  $w$  зі значенням  $\alpha = 75$ . Відмінність від (3.16) у тому, що замість різниці обсягів  $VD_t$  використовується баланс обсягів  $VB_t$ .

Для балансу ринкових обсягів продажів формула наступна (3.19):

$$MAS_{sell\ VB,t} = (Z_{HL_t} < P_\alpha(HL_t)) \wedge (Z_{VB_t} < P_\alpha(VB_t)), \quad (3.19)$$

де  $Z_{VB_t}$  – це z-показник різниці ринкових обсягів, а  $P_\alpha(VB_t)$  – це нижня межа розподілу  $VB_t$  у момент  $t$  за період  $w$  зі значенням  $\alpha = 25$ . Відмінність від (3.17) у тому, що замість різниці обсягів  $VD_t$  використовується баланс обсягів  $VB_t$ .

Отже, розроблено показник поглинання імпульсу, який має 5 різних реалізацій відповідно до типів ринкових обсягів та способів їх обчислення:

- 1)  $MAS_{V,t}$  – сумарні ринкові обсяги;
- 2)  $MAS_{buy\ VD,t}$  – різниця ринкових обсягів покупок;
- 3)  $MAS_{sell\ VD,t}$  – різниця ринкових обсягів продажів;
- 4)  $MAS_{buy\ VB,t}$  – співвідношення покупок до сумарних обсягів (баланс покупок);
- 5)  $MAS_{sell\ VB,t}$  – співвідношення продажів до сумарних обсягів (баланс продажів).

На рис. 3.5 зображено показник поглинання імпульсу (Momentum Absorption Score), а також z-показник різниці між максимальною та мінімальною цінами (High-

Low diff Z-score) та z-показник сумарних ринкових обсягів (Volume Z-score) за цей же період. Можна побачити, що значення показника нульове, коли:

- High-Low diff Z-score високе і значення Volume Z-score високе;
- High-Low diff Z-score високе, але значення Volume Z-score низьке;
- High-Low diff Z-score низьке і значення Volume Z-score низьке.

Однак, коли значення High-Low diff Z-score низьке, а значення Volume Z-score високе, то показник набуває значення 1, що свідчить про високі ринкові обсяги, які не мали достатньої сили, щоб змінити ціну суттєво.




Рис. 3.5 – Показник поглинання імпульсу сумарних обсягів

На рис. 3.6 зображено 5 показників поглинання обсягів: сумарних обсягів (MAS Volume), різниці обсягів покупок (MAS Buy Volume Delta), різниці обсягів продажів (MAS Sell Volume Delta), балансу обсягів покупок (MAS Buy Volume Balance) та балансу обсягів продажів (MAS Sell Volume Balance). Можна побачити, що часто

показники збігаються, особливо в місцях низької волатильності близько до локальних максимумів та мінімумів, де обсяги більші відносно попередніх значень.




Рис. 3.6 – Приклади показників поглинання імпульсу

### **3.3 Розробка удосконаленого методу прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу**

#### **3.3.1 Визначення цільових змінних, даних та моделей**

Ринок – це стохастична динамічна система, що генерує багато шуму [136]. Статистичні показники, такі як VWMA, MFI або MAS також можуть генерувати події, які не є достовірними щодо майбутньої ринкової динаміки, особливо за наявності структурних розривів та змін режимів волатильності. Як результат, багато подій призводять до збиткових угод. Тому активно досліджуються методи розв'язання проблеми відсіювання шумних подій: розпізнавання сигналів, які з вищою ймовірністю правильно опишуть майбутню ринкову динаміку, відкидаючи ті події, які є оманливими або неінформативними [137].

Ідея відсіювання хибно позитивних сигналів, що згенеровані Механістичною ковзною та Показником поглинання імпульсу, полягає в застосуванні алгоритмів машинного навчання в задачі бінарної класифікації: прогнозування чи буде сигнал збитковим (клас -1) чи прибутковим (клас 1). Такий підхід зміщує роль машинного навчання з безпосереднього прогнозування руху цін на здатність відсіювати шум, який підвищує стійкість сигналів та точність торгової стратегії.

Центральна проблема навчання з учителем для фінансових застосувань полягає у визначенні надійних та стійких цільових змінних. Традиційні підходи до бінарного маркування, такі як призначення мітки “купити” або “продати” на основі короткострокового руху ціни, нестабільні та можуть не враховувати властиву ринку волатильність та не стаціонарність. У зв'язку з цим використовується метод потрійних бар'єрів (Triple Barrier Method, або ж TBM), що запропонована Лопесом де Прадо (2018) [138]. Потрійний бар'єр оцінює те, як відпрацював сигнал в межах заздалегідь визначеного горизонту прогнозування, використовуючи три бар'єри:

- бар'єр тейк-профіту (Take-Profit, або ж TP): позитивний поріг руху ціни (наприклад, +2 стандартних відхилення), що вказує на прибуткову угоду;
- бар'єр стоп-лосу (Stop-Loss, або ж SL): негативний поріг руху ціни (наприклад, -2 стандартних відхилення), що вказує на збиткову угоду;

- часовий бар'єр: максимальний період утримання позиції (наприклад, кількість часових інтервалів), після якого позиція закривається за поточною ціною, яка може прибутковою або збитковою для угоди.

В залежності від того, який бар'єр було досягнуто першим, призначається відповідний клас:

- якщо ціна досягає TP до того як досягне SL або часового бар'єру з прибутком – тоді призначається клас “1” (прибуток);

- якщо ціна досягає SL до того як досягне TP або часового бар'єру зі збитками – тоді призначається клас “-1” (збиток).

Отже метод потрібних бар'єрів має наступні переваги:

1) стійкість до шуму: метод враховує коливання ціни, використовуючи стандартні відхилення як динамічну одиницю вимірювання, що змінюється з часом;

2) направлена визначеність: забезпечує чітку та засновану на правилах оцінку того, чи був сигнал спрямованим правильно в межах очікуваного горизонту;

3) усвідомлення часу: часовий бар'єр гарантує, що мітки не будуть зміщені необмежено довгими угодами або затриманими реакціями.

На рис. 3.7 зображено приклад методу потрібних бар'єрів, де ціна досягає нижнього бар'єру (SL) генеруючи збитки для довгої позиції.




Рис. 3.7 – Ціна досягає нижнього (SL) бар'єру

Для задачі класифікації, використовується набір ознак часових рядів, отримані з необроблених ринкових даних по відношенню до кожного сигналу. Зокрема, для кожного екземпляра сигналу побудовано матрицю  $4 \times 128$ , де кожен рядок представляє окрему ринкову ознаку, кожен стовпець відповідає часовому кроку упродовж 128-періодного історичного вікна, що веде до сигналу. Використано 4 наступні ринкові ознаки:

- 1) “close\_returns”: абсолютна різниця цін закриття, що фіксує інформацію про короткострокові тренди та імпульс. Ознака важлива для вимірювання варіації ціни;
- 2) “Volume”: сумарний ринковий обсяг, який вимірює рівень торгової активності. Ознака критично важлива як для Механістичної ковзної (обсяг як складова розрахунку показника), так і для MAS;
- 3) “volume\_balance”: описує тиск обсягів покупок/продажів, а тому надає інформацію про агресивну поведінку покупців та продавців;
- 4) “number\_of\_trades”: кількість угод, виконаних упродовж інтервалу, допомагає відрізнити великі угоди від багатьох малих.

Кожен з цих факторів надає інформацію, релевантну для динаміки цін та інтенсивності й напрямку обсягів. Представлені фактори краще допомагають алгоритмам машинного навчання вивчати дискримінаційні ознаки для відсіювання шумних сигналів. П'ять алгоритмів машинного навчання використовуються в цьому підході.

1. Класифікатор описової статистики (Summary Classifier). Алгоритм рахує середнє, мінімальне та максимальне значення, а також стандартне відхилення, а ще 25, 50 та 75 перцентилі для усіх розглянутих факторів. Після цього застосовує алгоритм Випадкового лісу на цих статистичних значеннях. Зведену статистику можна візуалізувати та пояснити, що сприяє прозорості моделі. Також алгоритм простий, швидкий та може працювати з відносно невеликими наборами даних, але він не здатний виявляти складні закономірності в даних.

2. Catch22 (CAnonical Time-series CHaracteristics) класифікатор. Алгоритм розраховує 22 ретельно відібрані ознаки часових рядів, які були автоматично обрані з набагато більшої множини (приблизно 7500 ознак) такі як: лінійна та нелінійна

автокореляція, послідовні різниці, розподіли значень та викиди, а також властивості масштабування флуктуацій [139]. Після чого застосовує алгоритм Випадкового лісу на цих ознаках. Catch22 краще фіксує динамічні зміни та аномальні значення часових рядів. Усі 22 ознаки добре задокументовані та ґрунтуються на статистичній теорії, а сам алгоритм простий та швидкий. Однак не всі ознаки можуть бути релевантними на різних ринкових режимах.

3. Rocket класифікатор. Цей алгоритм класифікації часових рядів на основі випадково ініціалізованих згорткових ядер для перетворення вхідних часових рядів у багатовимірний простір ознак [140]. Велика кількість (зазвичай 10000) одновимірних згорткових ядер генерується випадковим чином. Ядра відрізняються довжиною, шириною та вагами. Для кожного виходу ядра обчислюються дві прості підсумкові ознаки: максимальне значення та частка позитивних значень. Утворюється велика розріджена матриця ознак фіксованого розміру. Перетворені вектори ознак передаються до простої лінійної моделі, такої як логістична регресія, для класифікації. Rocket класифікатор фіксує локальні закономірності у часових рядах, які можуть бути пов'язані з початком імпульсу або аномалії. Також алгоритм стійкий до нестационарності часових рядів. Однак згенеровані випадкові ядра важко інтерпретувати, що ускладнює пояснюваність моделі.

4. TimeCNN класифікатор. Це архітектура глибокої нейронної мережі, яка застосовує одновимірні згорткові шари безпосередньо до часових рядів. На відміну від традиційних CNN, що використовуються для зображень, TimeCNN оптимізований для послідовностей, зосереджуючись на захопленні часових закономірностей [141]. Ядра згортки вивчаються під час навчання, що дозволяє моделі адаптуватися до динаміки часових рядів. TimeCNN навчається безпосередньо з даних, тому немає критичної потреби в конструюванні ознак. Однак, як і для більшості алгоритмів глибокого навчання, необхідно використовувати більшу кількість даних, щоб знизити ймовірність та ступінь перенавчання. Також алгоритм вимагає більше часу для навчання.

5. Stacking класифікатор. П'ятий та останній алгоритм класифікації це мета модель (частіше логістична регресія), яка навчається на вихідних даних (прогнозах)

базових навчальних моделей: Summary, Catch22 Rocket і TimeCNN. Кожна з цих моделей генерує прогнози (ймовірності класів) для навчальних даних, а мета модель отримує їх як вхідні дані та класифікує за методом потрібних бар'єрів на прибуткові та збиткові угоди. Тобто ця мета-модель навчається оптимально поєднувати вихідні дані базових моделей для отримання остаточного прогнозу [142]. Такий алгоритм може підвищити точність прогнозів, поєднуючи різноманітні моделі. Однак пояснюваність Stacking моделі буде ускладнено.

### **3.3.2 Визначення методу машинного навчання для інтелектуальної фільтрації торгових сигналів**

Описані вище алгоритми навчаються та перевіряються за допомогою Ковзної валідації часових рядів [143]. Такий метод перевірки імітує, як модель працюватиме в реальному сценарії, шляхом ітеративного навчання на зростаючому історичному вікні та тестування на майбутніх даних, які слідує винятково після тренувальних даних у часовому вимірі. На кожній ітерації вікно навчання переміщується вперед, щоб включити новіші дані, а тестовий набір розташовується безпосередньо після вікна навчання, зберігаючи хронологічний порядок. Цей ітеративний процес триває до кінця набору даних. Цей метод гарантує відсутність витоку інформації з майбутнього в минуле, що має вирішальне значення для прогнозування часових рядів. На рис. 3.8 зображено серію навчальних та тестових наборів, де сині спостереження утворюють навчальні набори, а помаранчеві спостереження – тестові набори. Сірі спостереження між синіми та помаранчевими – це пропуски (gaps) між тренувальними на тестувальними наборами даних довжиною у третій часовий бар'єр + 1 спостереження. Це зроблено для того, щоб не мати накладань цільових змін на тренувальному та тестовому датасетах.






Рис. 3.8 – Ілюстрація ковзної валідації, де сині спостереження утворюють навчальні набори, а помаранчеві спостереження – тестові набори [143]

Наступні метрики точності моделей обчислюється для кожного тестового набору:

1) ROC AUC (Compute Area Under the Receiver Operating Characteristic Curve) – це показник точності, який кількісно визначає здатність бінарного класифікатора розрізняти два класи. Крива ROC відображає коефіцієнт істинно позитивних результатів (TPR) у порівнянні з коефіцієнтом хибно позитивних результатів (FPR) при різних порогах прийняття рішення. AUC (площа під кривою) представляє ймовірність того, що класифікатор ранжує випадково вибраний позитивний приклад вище, ніж випадково вибраний негативний. Значення AUC варіюються від: 0.5 – випадкове вгадування (відсутність дискримінаційної здатності), 1.0 – ідеальна класифікація та менше 0.5 – систематична неправильна класифікація (наприклад, інверсія класів) [144];

2) Precision – показник точності кількісно визначає частку позитивних прогнозів, які насправді є правильними (3.20). Чим вище значення точності тим модель більш стійка до хибно позитивних прогнозів відносно загальної кількості істинно позитивних прогнозів:

$$P = \frac{TP}{TP + FP}, \quad (3.20)$$

де  $TP$  – це кількість істинно позитивних прогнозів, а  $FP$  – це кількість хибно позитивних прогнозів;

3) Recall – також відомий як чутливість або істинний коефіцієнт позитивних результатів, вимірює частку істинно позитивних прогнозів, які були правильно ідентифіковані класифікатором (3.21). Чим вище значення чутливості тим більша ймовірність, що модель не пропустить багато прибуткових сигналів:

$$R = \frac{TP}{TP + FN}, \quad (3.21)$$

де  $TP$  – це кількість істинно позитивних прогнозів, а  $FN$  – це кількість хибно негативних прогнозів;

4) Average Precision (AP) – підсумовує криву Precision - Recall як зважене середнє значень Precision для всіх порогових значень моделі (3.22). Чим більше значення AP тим краще модель витримує гнучкий баланс між Precision та Recall:

$$AP = \sum_n (R_n - R_{n-1})P_n, \quad (3.22)$$

де  $P$  – це точність, а  $R$  – це чутливість.

5) Sharpe Ratio – вимірює наскільки надлишкова дохідність (тобто дохідність вище без ризикової ставки) досягається на одиницю волатильності (ризик) розраховані за щорічні періоди (Annualized). Він визначається через (3.23):

$$S_a = \frac{E(R_a - R_b)}{\sigma_a} \times \sqrt{N}, \quad (3.23)$$

де  $R_a$  – це дохідність активу,  $R_b$  – це дохідність безризикового активу,  $\sigma_a$  – це стандартне відхилення дохідності активу, а  $N$  – це кількість періодів на рік (наприклад, 365 для денного інтервалу, 12 для інтервалу місяць).

Коефіцієнт Шарпа розраховується на основі дохідності активу за результатами бектестів проведених за правилами потрібного бар'єру, де прогнози моделей використовуються для входу в угоду. При цьому дохідність без ризикового активу  $R_b$  розглядається як 0.

Багатокритеріальний підхід до прийняття рішень (Multi-Criteria Decision-Making, або ж MCDM) [145] використано для ранжування моделей за ключовими 5 метриками, описаними вище. Кожну метрику було нормалізовано за допомогою Min-Max методу, щоб привести всі значення до порівнянної шкали. Потім для кожної

конфігурації було розраховано кінцевий складений бал як зважену суму нормалізованих значень метрик (3.24).

$$Score = w_{ROC\ AUC} ROC\ AUC + w_P P + w_R R + w_{AP} AP + w_S S, \quad (3.24)$$

де  $w_{ROC\ AUC}$  – це ваги  $ROC\ AUC$ ,  $w_P$  – це ваги  $Precision$ ,  $w_R$  – це ваги  $Recall$ ,  $w_{AP}$  – це ваги  $AP$ , а  $w_S$  – це ваги  $Sharpe\ Ratio$ .

Важливо формувати розподіл ваг з врахуванням логіки відсіювання хибно позитивних прогнозів. Приклад ваг представлений в таблиці 3.1, де найвищі значення мають  $ROC\ AUC$ ,  $Precision$  та  $Sharpe\ Ratio$ , оскільки важливо, щоб модель була здатна до прогнозування якнайкраще ( $ROC\ AUC$ ) та генерувала мінімум хибно позитивних прогнозів ( $Precision$  та  $Sharpe\ Ratio$ ), мінімізуючи збитки.

Таблиця 3.1

Приклад ваг для ранжування моделей за допомогою MCDM

Метрика	Ваги
ROC AUC	0.25
Precision	0.3
Recall	0.05
AP	0.1
Sharpe Ratio	0.3

Метод машинного навчання для відсіювання хибно позитивних торгових сигналів, що згенеровані показниками механістичного підходу, формалізовано в наступному вигляді (3.25):

$$M = \arg \max_{M_j \in m} \Phi(f_j(\text{TBM}(\text{FE}(g(MM_t, MAS_t))))), \quad (3.25)$$

де:

- 1)  $g$  – генерація механістичних показників: механістичної ковзної  $MM_t$  та показника поглинання імпульсу  $MAS_t$ ;
- 2) FE – формування статистичних факторів на основі згенерованих механістичних показників;
- 3) TBM – застосування методу потрійних бар'єрів для анотації датасету;
- 4)  $f_j$  – машинне навчання задачі класифікації;
- 5)  $\Phi$  – обчислення Score (3.24);
- 6)  $M_j$  – модель з множини моделей  $m = \{Summary, Catch22, Rocket, TimeCNN, Stacking\}$ ;
- 7)  $M$  – оптимальна модель.

Метод створює відранжований список, з якого можна обирати не тільки модель з найвищим Score, але й будь-яку нижчу за переліком. На рис. 3.9 узагальнено схематизовано метод машинного навчання для відсіювання хибно позитивних торгових сигналів, що згенеровані показниками механістичного підходу.

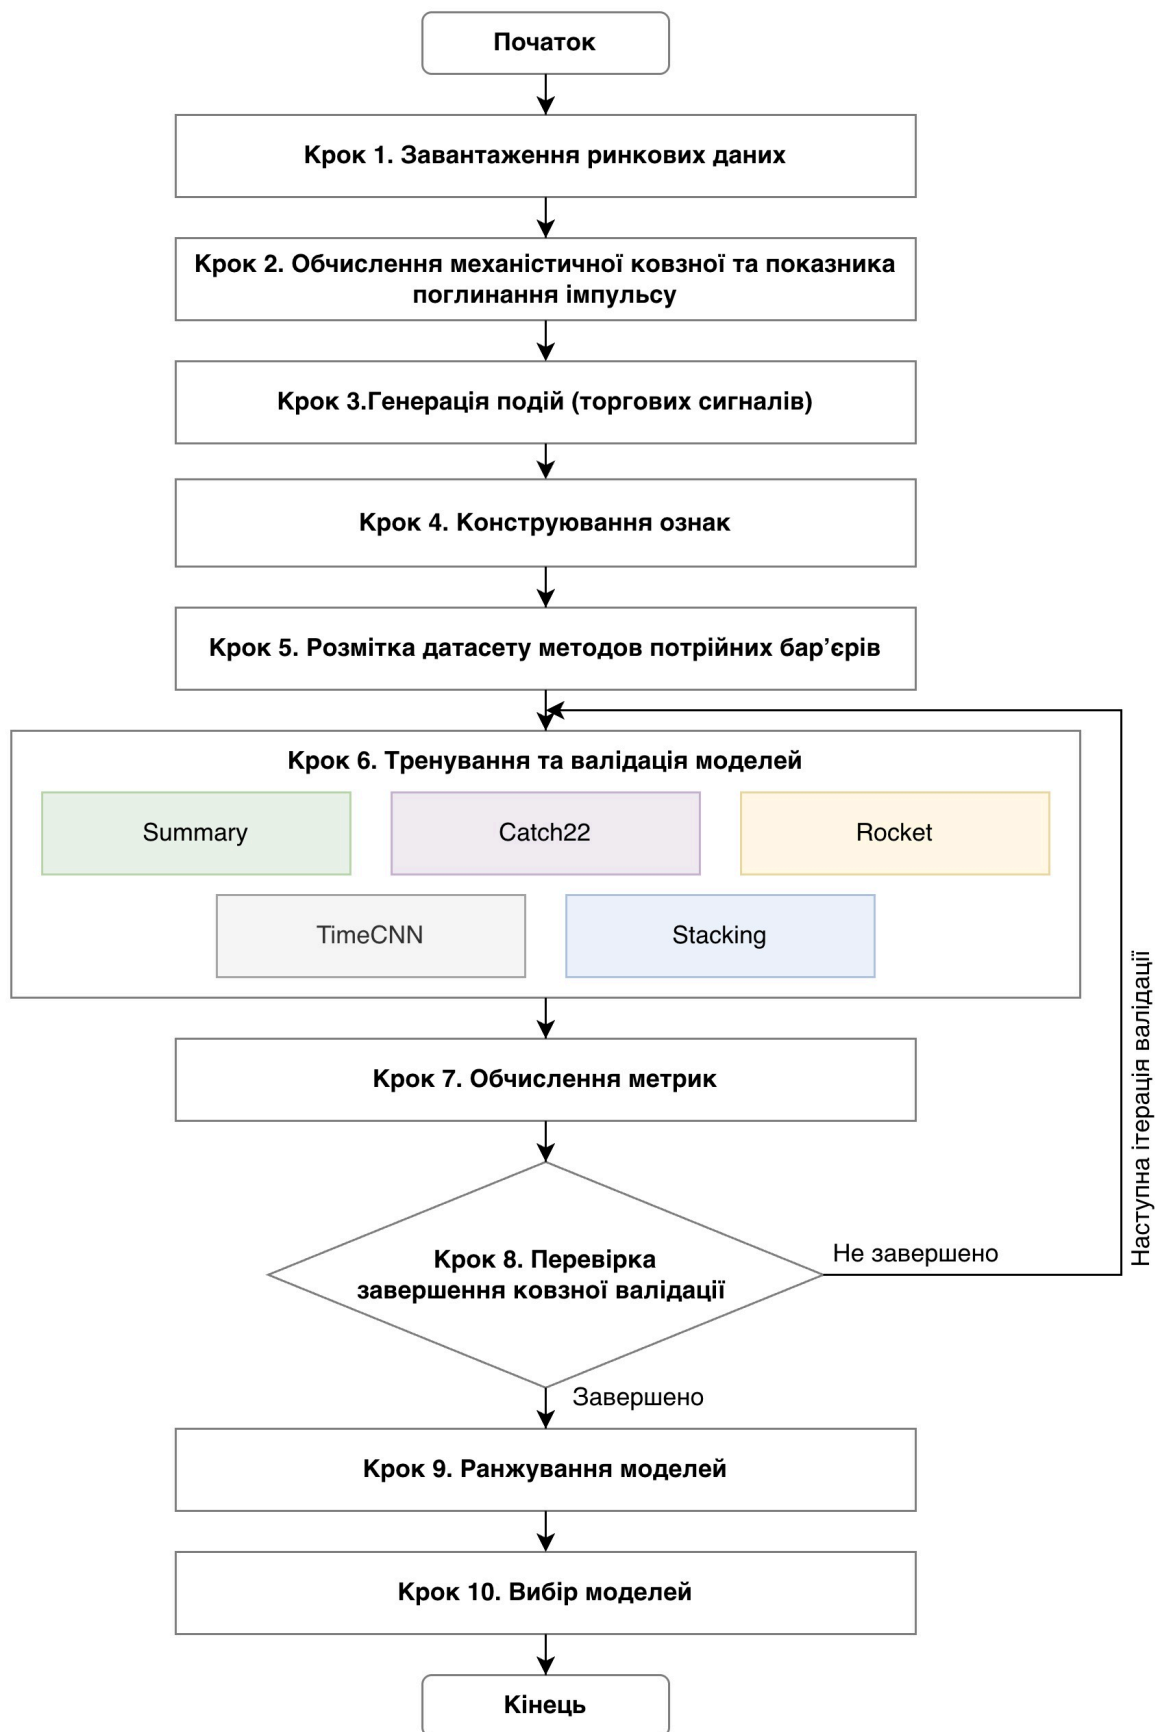


Рис. 3.9 – Схема-ілюстрація удосконаленого методу прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу

### 3.4 Розробка архітектурних рішень реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи

#### 3.4.1 Алгоритм реалізації методу машинного навчання для інтелектуальної фільтрації торгових сигналів

Алгоритм поєднує обчислення показників механістичного підходу (GMI та MAS), машинне навчання та ретроспективне тестування подій. Вхідними даними системи є потік ринкових спостережень (3.26):

$$D_t = \{O_t, H_t, L_t, C_t, V_t, N_t\}, \quad (3.26)$$

де:

- 1)  $O_t$  – ціна відкриття;
- 2)  $H_t$  – максимальна ціна;
- 3)  $L_t$  – мінімальна ціна;
- 4)  $C_t$  – ціна закриття;
- 5)  $V_t$  – ринковий обсяг;
- 6)  $N_t$  – кількість угод.

Виходом системи є бінарне рішення (3.27):

$$\hat{y}_t \in \{0, 1\}, \quad (3.27)$$

де:

- 1) 0 – сигнал ідентифіковано як потенційно збитковий;
- 2) 1 – сигнал ідентифіковано як потенційно прибутковий.

Алгоритм реалізований з урахуванням наступних вимог:

- 1) Потокового оновлення ринкових даних та статистик;
- 2) Відсутності витоку інформації між навчальними та тестовими вибірками;
- 3) Модульності компонентів;
- 4) Відтворюваності експериментів;
- 5) Масштабованості до великих часових рядів;
- 6) Розділення етапів навчання та застосування (інференсу) моделей.

На відміну від класичних потокових систем, машинне навчання в запропонованому алгоритмі використовується не для прямого прогнозування цінового руху, а як відсіювання сигналів, згенерованих механістичними показниками, щоб прийняти рішення про майбутню динаміку часового ряду: тобто прогнозування наслідків рішень, а не безпосередньо значення станів простору (state-space). Алгоритм складається з двох процесів (рис. 3.10):

- 1) процес навчання моделей;
- 2) процес інференсу моделей.

Навчання запускається періодично (наприклад, один раз на тиждень, місяць або після накопичення достатньої кількості нових ринкових даних). Основною задачею є побудова, оцінювання та відбір оптимальних моделей машинного навчання. Навчання має наступні етапи:

1) отримання та підготовки даних: історичні ринкові дані завантажуються з біржових API, а далі відбувається синхронізація часових міток, усунення пропущених спостережень, контроль коректності OHLCV-значень, нормалізація формату даних, перевірка часової послідовності;

2) обчислення показників механістичного підходу: на основі очищених часових рядів обчислюються механістична ковзна, показник поглинання імпульсу, та супутні ознаки обсягів і кількості угод. На цьому етапі формується множина торгових подій, де кожен сигнал містить: часову мітку, напрямок угоди, тип сигналу. Для прискорення обчислень використовуються: JIT-компіляція та кешування проміжних обчислень;

3) формування датасету: для кожного сигналу формується історичне вікно (матриця) розмірністю  $4 \times 128$ , що містить зміну ціни закриття, обсяг, дисбаланс обсягів та кількість угод;

4) конструювання цільової змінної: для формування цільових змінних використовується метод потрійних бар'єрів, що в результаті формує бінарну змінну, яка визначає прибутковість або збитковість угоди;

5) тренування моделей: у цьому модулі навчається множина моделей з підрозділу 3.3.1. Для навчання моделей використовується ковзна валідація часових рядів;

6) оцінювання моделей: для кожної моделі обчислюються метрики з підрозділу 3.3.2;

7) ранжування моделей: для кожної моделі розраховується показник Score (3.24) і виконується задача максимізації (3.25). Після ранжування топ-k моделей зберігаються у реєстр моделей;

8) реєстрація моделей: збереження моделей, параметрів препроцесінгу, значення метрик, дати навчання та версії моделей;

9) планування тренувань моделей: в цій частині відбувається контроль часу та активація навчання моделей, якщо минуло N кількість хвилин.

Процес інференсу моделей працює в режимі реального часу та має наступні етапи:

1) потокове отримання даних: нові ринкові дані надходять від бірж у режимі реального часу;

2) обчислення показників механістичного підходу: аналогічний етапу процесу тренування моделей;

3) формування датасету: аналогічний етапу процесу тренування моделей;

4) інференс моделей: з реєстру моделей завантажується найкраща модель, після чого виконується інференс та обчислюється фінальне рішення за обраним порогом ймовірності;

5) виконання сповіщень: якщо рішення ухвалене в модулі №4 дорівнює 1 (потенційно прибуткова угода), то генерується сповіщення, а сама подія записується в журнал;

6) планування наступного інференсу моделей: в цій частині відбувається контроль виконання інференсу згідно із заданим часовим інтервалом;

Алгоритм завершується у випадках, коли користувач зупиняє процес програми, а також, коли планування наступної ітерації інференсу або тренування моделей стає неможливе (наприклад, критична помилка в будь-якому етапі алгоритму).



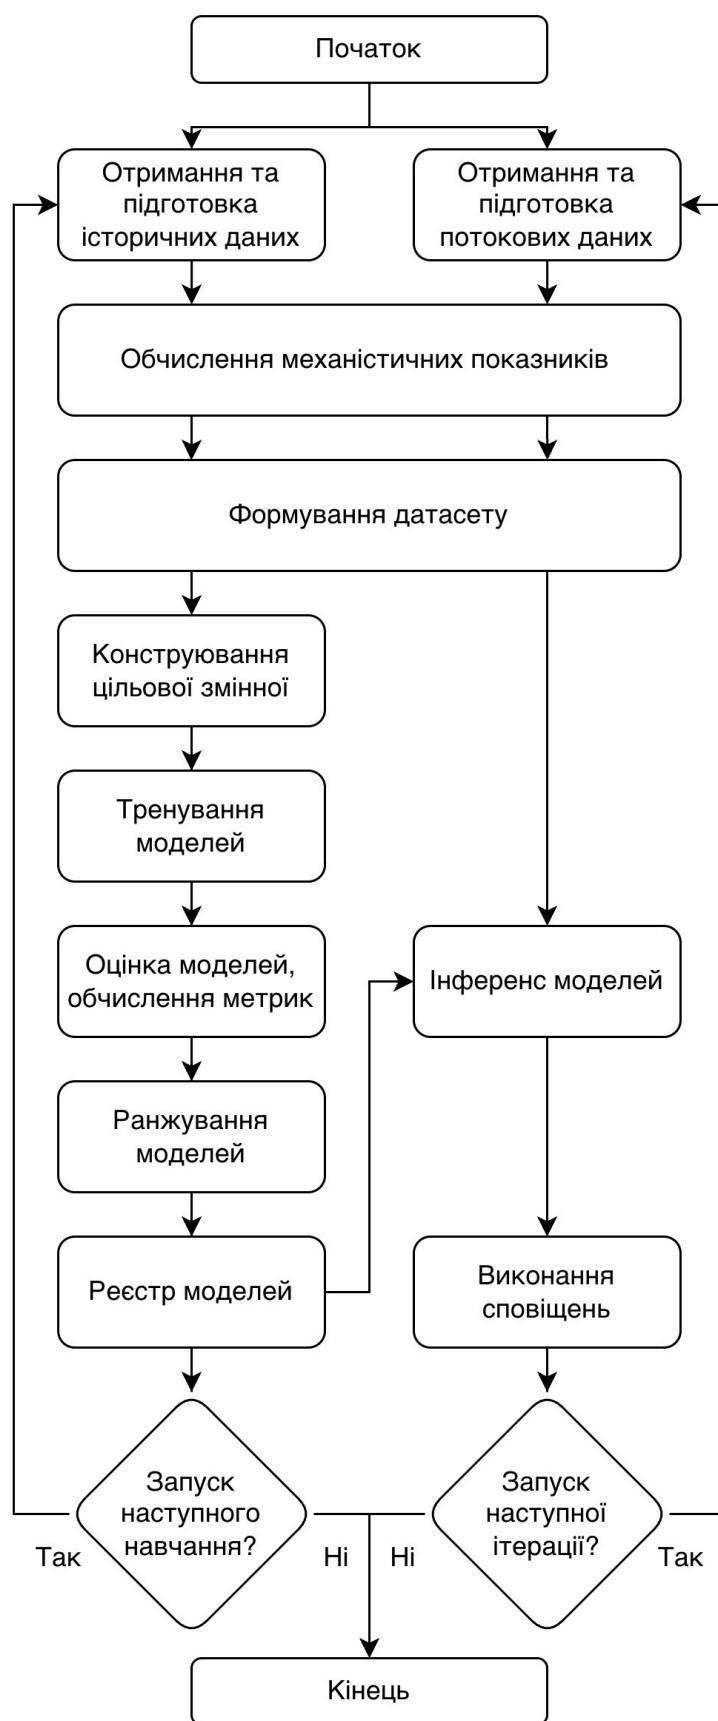


Рис. 3.10 – Алгоритм реалізації навчання та інференсу моделей машинного навчання для інтелектуальної фільтрації торгових сигналів

### 3.4.2 Архітектура програмної реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи

Програмна реалізація методів аналізу та прогнозування динаміки ринку криптовалют, розроблена з метою обчислення показників механістичного підходу (GMI і MAS) та відсіювання хибно позитивних подій, що згенеровані цими показниками, за допомогою моделей машинного навчання в задачі класифікації часових рядів. Система реалізує модульну монолітну багаторівневу архітектуру з наступними рівнями:

- 1) рівень отримання даних: встановлює зв'язок між зовнішніми API для отримання даних та їх подальшого збереження на локальному сховищі;
- 2) логічний рівень: обчислення показників механістичного підходу та інші методи для аналізу динаміки часових рядів;
- 3) рівень машинного навчання: керує життєвим циклом моделей, їх навчанням та валідацією;
- 4) рівень презентації: забезпечує інтерактивну візуалізацію та доступ до REST API.

Узагальнено, архітектура програмної реалізації (рис. 3.11) та діаграма класів (рис. 3.12) має наступні складові:

- 1) Криптовалютні біржі: виступають в ролі основних постачальників даних;
- 2) API Контектор: встановлює зв'язок з криптовалютними біржами для завантаження та подальшого збереження даних; керується за допомогою менеджера даних;
- 3) Менеджер даних: керує завантаженням історичних та потокових даних, контролює наявність даних та їх повноту для навчання та інференсу моделей, записує історичні дані в Parquet сховище, забезпечує безперебійне функціонування модулю Машинного навчання;
- 4) Parquet сховище: зберігає історичні дані для навчання та відображення у візуальному інтерфейсі;
- 5) Машинне навчання: з отриманих даних від Менеджера даних формує датасети для тренування та інференсу моделей, використовує результати обчислень з

модуля Механістичні показники для генерування подій та подальшого їх відсіювання, контролює навчання та інференс моделей, зберігає моделі у Сховище моделей;

6) Механістичні показники: забезпечує обчислення GMI та MAS показників;

7) Сховище моделей: зберігає моделі з модуля Машинне навчання;

8) Безперервне навчання моделей: планує та контролює періодичне навчання моделей машинного навчання на нових даних із заданою частотою;

9) REST API: забезпечує доступ до механістичних показників та прогнозів моделей через API;

10) Інтерфейс (UI): забезпечує для Користувача просту візуалізацію OHLCV даних, механістичних показників, прогнозів моделей машинного навчання.

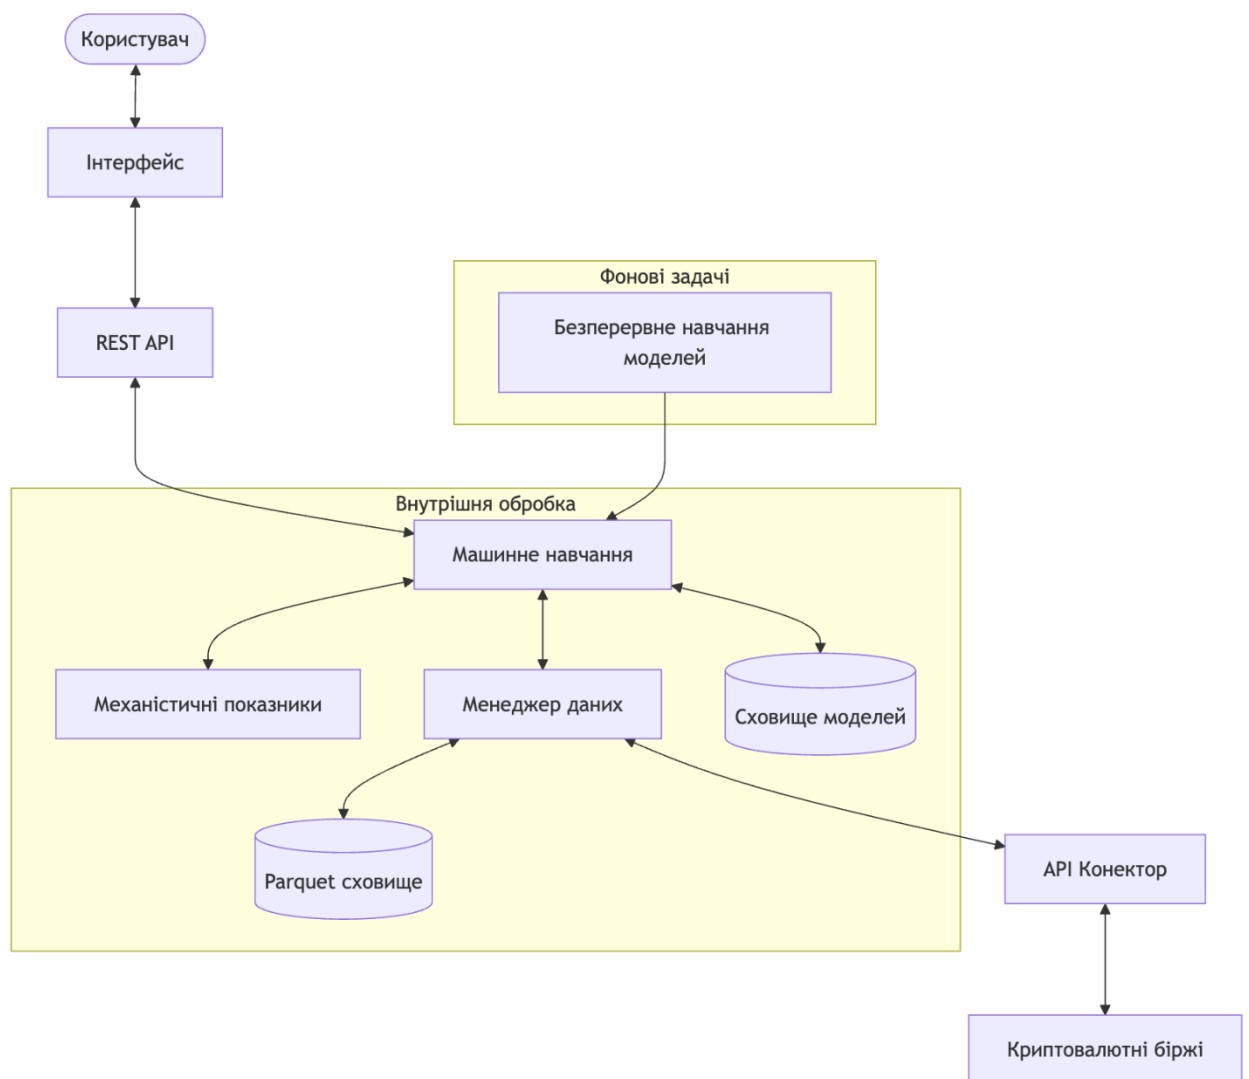


Рис. 3.11 – Архітектура програмного забезпечення для аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи

У свою чергу, StackingClassifier – це алгоритм, який навчається з прогнозів TSClassifier (Summary, Rocket та інші моделі), і є окремою моделлю.

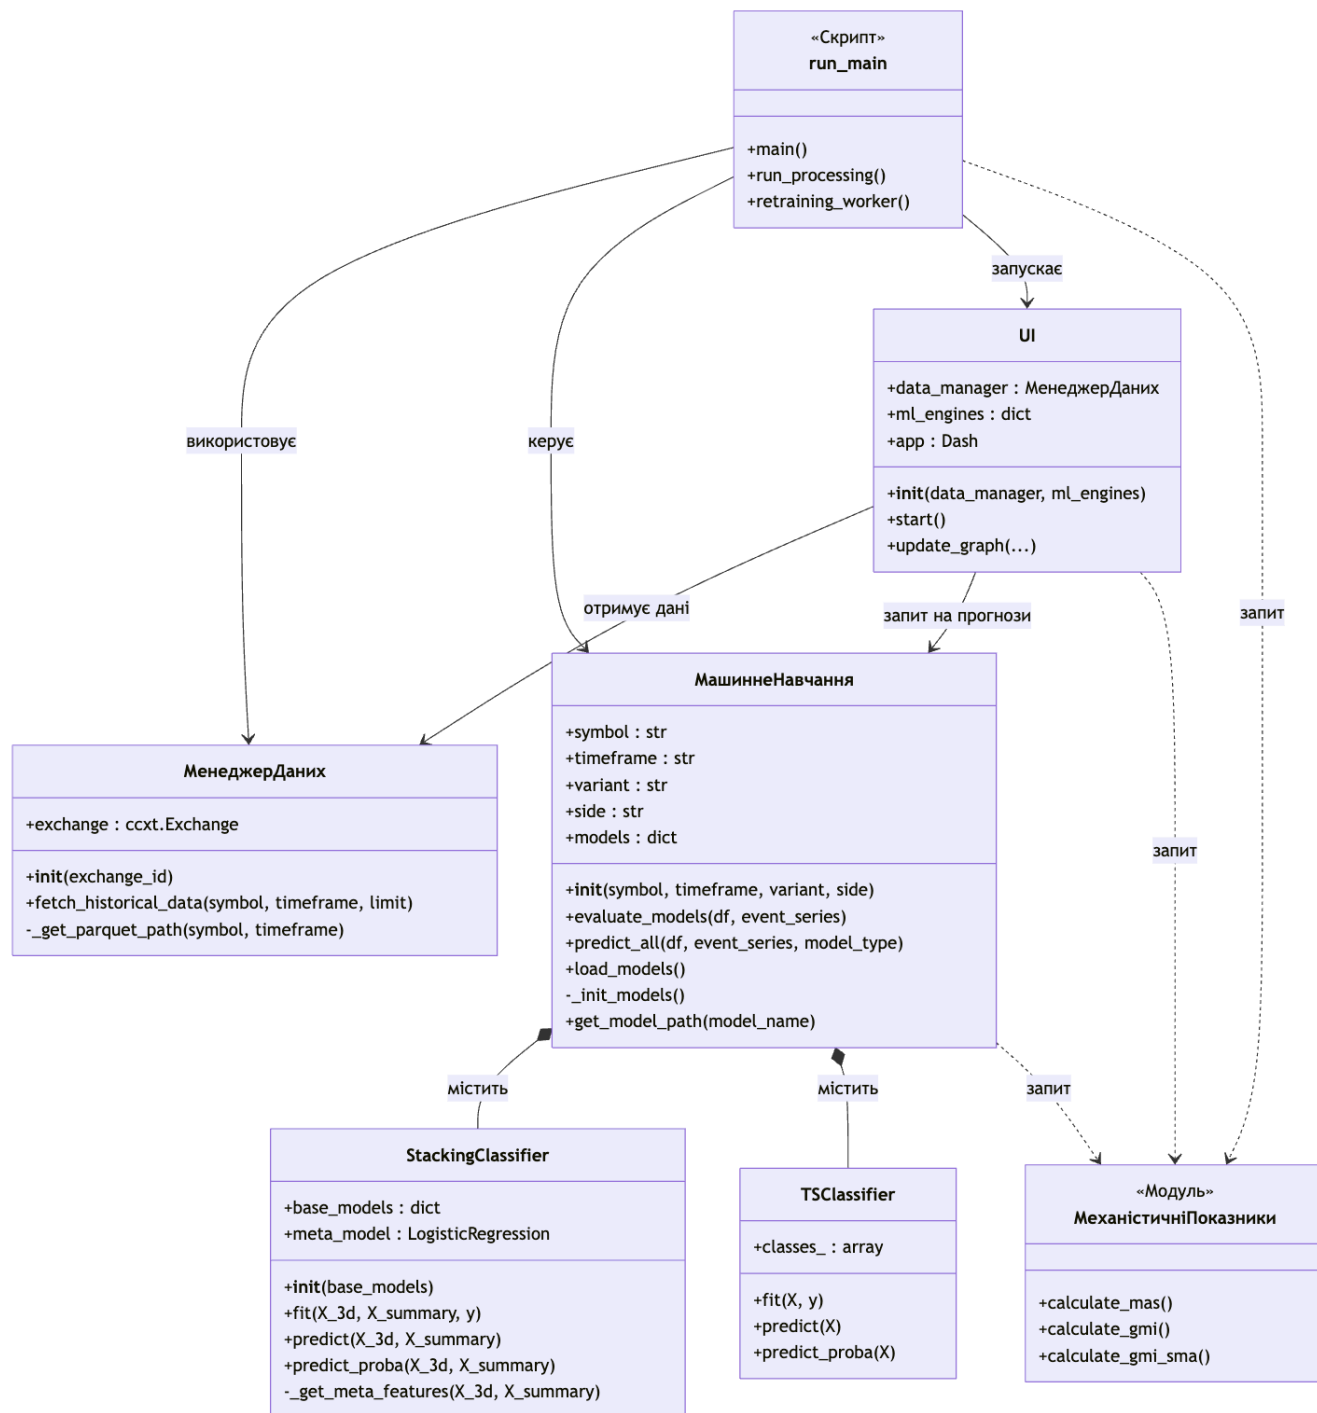


Рис. 3.12 – Діаграма класів програмної реалізації для аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи

Діаграма послідовності (рис. 3.13) відображає взаємодії складових системи впорядкованих за часом. Безперервне навчання забезпечує періодичне навчання моделей на нових даних. Для цього необхідно завантажити історичні дані, які, за

допомогою Менеджера даних, періодично завантажуються з криптовалютних бірж та записуються у сховище. Ковзна валідація забезпечує ітеративне оцінювання та ранжування моделей.

Екранні форми програмної реалізації наведено в Додатку Б.

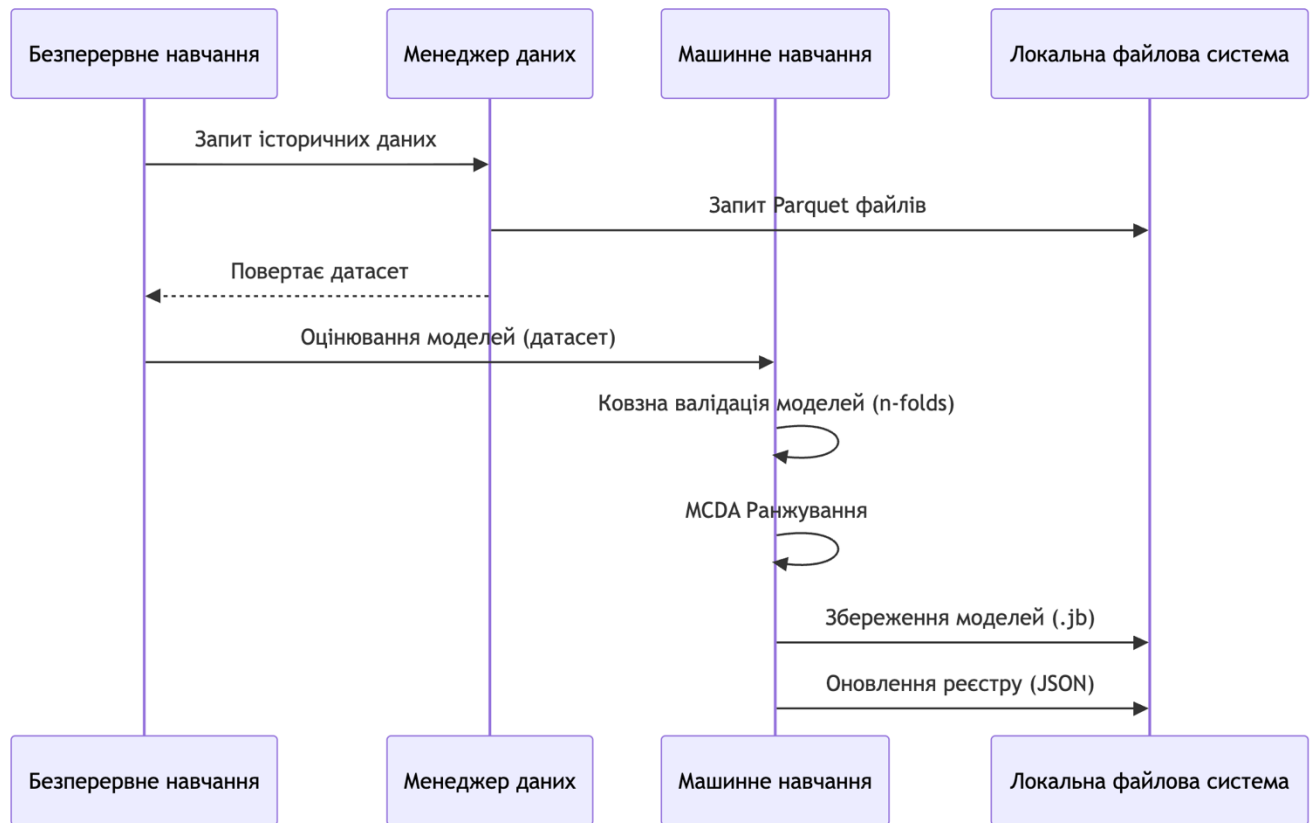


Рис. 3.13 – Діаграма послідовності процесів безперервного навчання та інференсу моделей машинного навчання для аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи

Для обчислення показників механістичного підходу (GMI та MAS) використовуються методи динамічної компіляції (JIT-компіляції) та кешування, які дозволяють перетворювати алгоритми обробки часових рядів у машинний код безпосередньо перед виконанням. Такий підхід дозволяє пришвидшити обчислення показників. Основні методи оптимізації включали:

1) кешування інструкцій: повторне використання вже скомпільованих машинних кодів дозволяє уникнути повторної фази аналізу коду при наступних запусках;

2) паралелізація обчислень: розподіл завдань між ядрами процесора на рівні низькорівневих циклів обробки даних забезпечує лінійне або близьке до лінійного прискорення при роботі з багатовимірними часовими рядами;

3) мінімізація використання пам'яті: пряма робота з буферами даних без створення проміжних об'єктів та додаткових копіювань у пам'яті.

Обчислення механістичних показників GMI та MAS відбувається у формі функцій, що виконуються у ЛІТ-середовищі динамічної компіляції. Система складається з таких функціональних блоків (рис. 3.14):

1) Часові ряди: на вхід системи подаються часові ряди, які містять послідовності впорядкованих у часі спостережень (3.28):

$$X = \{x_1, x_2, \dots, x_n\}, \quad (3.28)$$

де  $x_i$  – значення сигналу або спостереження в момент часу  $i$ .

Цей блок відповідає за завантаження вхідних даних, їх базову структурування та передачу до обчислювальних модулів;

2) GMI функція: цей блок реалізує алгоритм обчислення показника GMI;

3) MAS функція: цей блок реалізує алгоритм обчислення показника MAS;

4) Bytecode Analysis: на цьому етапі система аналізує внутрішнє представлення Python-функцій у формі байткоду. Виконується виявлення арифметичних операцій, циклів, умовних переходів та звернень до пам'яті. Мета цього блоку полягає в тому, щоб побудувати формальну модель виконання алгоритму перед компіляцією;

5) Генерація проміжного представлення (IR генерація): після аналізу байткоду формується IR (Intermediate Representation) – проміжне представлення алгоритму. Його можна формально представити як (3.29):

$$IR = (O, D, C), \quad (3.29)$$

де  $O$  – множина операцій,  $D$  – потоки даних,  $C$  – обчислювальні залежності. Цей рівень дозволяє оптимізатору працювати не з Python-кодом, а з формалізованою обчислювальною структурою;

6) Type Inference: у цьому блоці система автоматично визначає типи змінних, що використовуються у функціях GMI та MAS (3.30):

$$x_i \rightarrow float64, \quad (3.30)$$

це дозволяє прибрати перевірки типів змінних під час виконання та підготувати код до компіляції;

7) IR оптимізація: на цьому етапі виконується оптимізація обчислювального графа шляхом усунення дублювання обчислень, об'єднання циклів та спрощення арифметичних виразів. Мета цього етапу в тому, щоб мінімізувати кількість операцій, які будуть виконуватись процесором;

8) LLVM JIT: оптимізоване проміжне представлення передається до JIT-компілятора на базі LLVM. Тут виконується генерація нативного коду (3.31):

$$f(X) \rightarrow f_{naive}(X), \quad (3.31)$$

це усуває додаткові витрати на виконання алгоритму;

9) Машинний код: на цьому етапі алгоритми GMI та MAS представлені у вигляді оптимізованого машинного коду, який виконується безпосередньо центральним процесором. Це має такі переваги як використання SIMD-інструкцій, багатопотокове виконання та продуктивне використання кеш-пам'яті CPU. Час виконання після компіляції (3.32):

$$T_{native} \ll T_{python}. \quad (3.32)$$

10) Кешування: скомпільований машинний код зберігається в кеші для повторного використання. При наступних застосуваннях пропускаються етапи аналізу, не виконується повторна компіляція і алгоритм одразу переходить до виконання. Формально визначення наступне (3.33):

$$T_{repeat} < T_{initial}. \quad (3.33)$$

11) GMI та MAS значення: після виконання оптимізованого машинного коду система повертає значення показників GMI та MAS. Ці значення використовуються для подальшого опрацювання модулем машинного навчання;

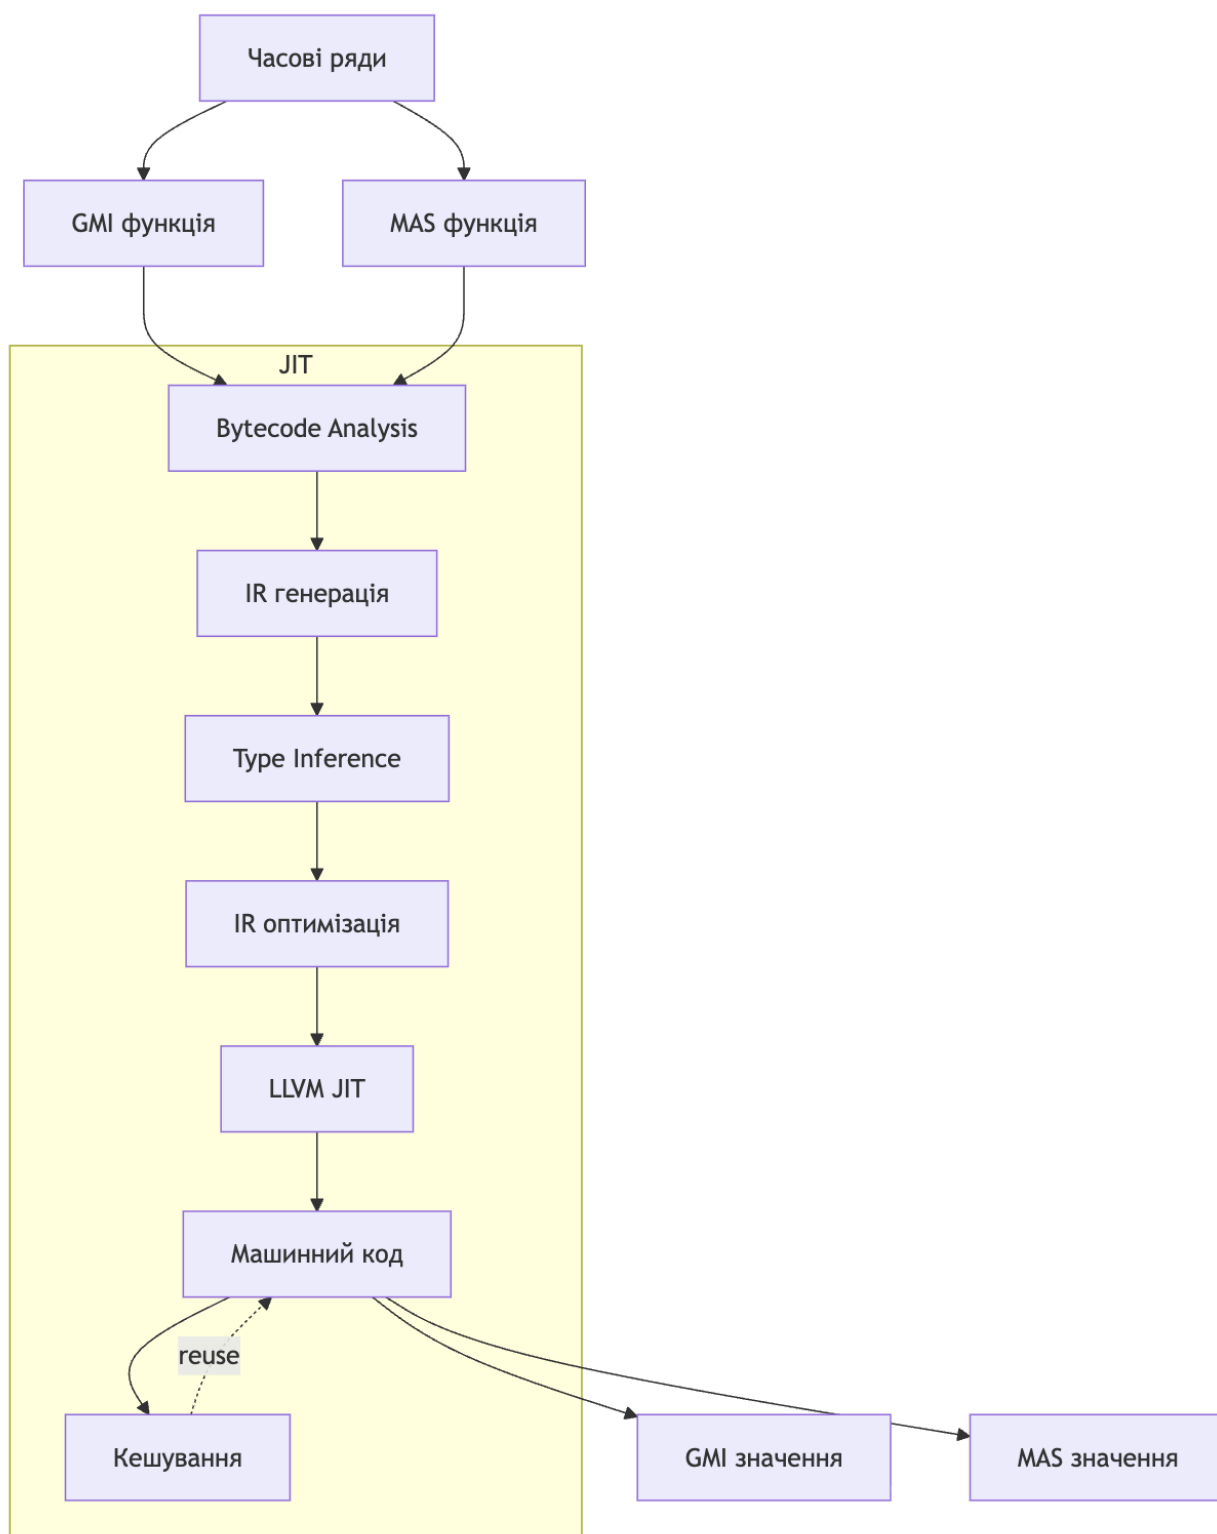


Рис. 3.14 – Схема системи обчислення показників механістичного підходу за допомогою JIT-компіляції у складі єдиної інтелектуальної системи



### Висновки до розділу 3

Удосконалено метод механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці, що дозволило формалізовано оцінювати взаємодію попиту та пропозиції в умовах високої волатильності та нестационарності ринку. Встановлено, що використання абсолютної різниці обсягів у формулі узагальненого імпульсу дозволяє уникнути проблем інтерпретації при від'ємних значеннях різниці обсягів покупок та продажів. Продемонстровано, що запропоновані модифікації дозволяють ідентифікувати дисбаланси між ринковими покупками та продажами, які є ключовими індикаторами зміни цінових тенденцій.

Вперше розроблено показник поглинання імпульсу (Momentum Absorption Score, MAS), який ґрунтується на статистичному виявленні зон низької волатильності при аномально високих торгових обсягах за допомогою z-оцінок та процентильного аналізу і є складовою удосконаленого методу механістичного аналізу динаміки криптовалютних активів, що дозволило ідентифікувати приховані фази накопичення та розподілу активів, які передують значним ціновим рухам. Розроблено п'ять спеціалізованих модифікацій показника поглинання імпульсу відповідно до різних типів ринкових обсягів:

- 1) сумарні ринкові обсяги;
- 2) різниця ринкових обсягів покупок;
- 3) різниця ринкових обсягів продажів;
- 4) баланс ринкових обсягів покупок;
- 5) баланс ринкових обсягів продажів.

Продемонстровано, що розроблені показники часто збігаються в зонах низької волатильності поблизу локальних екстремумів, де спостерігаються підвищені обсяги торгів, що дозволяє ідентифікувати потенційні торгові можливості на ранніх стадіях формування цінового руху, що може суттєво підвищити прибутковість торгових стратегій шляхом входу в позицію до початку активного імпульсного руху ціни.

Удосконалено метод прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на

основі показників механістичного аналізу (механістичної ковзної та показника MAS) із застосуванням ансамблевого машинного навчання та класифікації прибутковості подій за методом потрібних бар'єрів, що дозволило підвищити точність ідентифікації інформативних сигналів та мінімізувати вплив ринкового шуму. У якості вхідних ознак для моделей використано ключові ринкові характеристики, що відображають динаміку ціни, обсягів, дисбалансів і торгової активності. Запропоновано п'ять різних алгоритмів до побудови моделей класифікації: Summary, Catch22, ROCKET, TimeCNN та Stacking. Для оцінки точностей моделей застосовано ковзну валідацію, що зберігає хронологічний порядок та імітує реальні ринкові умови. Застосовано метрики: ROC AUC, Precision, Recall та Average Precision, які дозволяють всебічно оцінити здатність моделей розрізняти прибуткові й збиткові сигнали. Моделі ранжуються за допомогою методу MCDM на основі представлених метрик, щоб визначити оптимальні конфігурації відповідно до критеріїв зважування.

Дістали подальшого розвитку архітектурні рішення реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи за рахунок впровадження модульної монолітної структури з розділеними контурами навчання та інференсу, що дозволило забезпечити ізоляцію ресурсоємних процесів та спростити інтеграцію механістичних показників. Система включає спільні модулі розрахунку механістичних показників, генерації торгових сигналів та побудови ознак, після чого обчислювальний процес розгалужується на навчання моделей та інференсу із використанням оптимальної моделі, яка завантажується з реєстру моделей. Це забезпечує модульність, масштабованість та обчислювальну продуктивність. Програмна реалізація має простий інтерфейс для взаємодії користувача зі застосунком, а також REST API.

## РОЗДІЛ 4. РЕЗУЛЬТАТИ ДОСЛІДЖЕНЬ МЕТОДІВ АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ДИНАМІКИ РИНКУ КРИПТОВАЛЮТ

### 4.1 Оглядове порівняння методів аналізу торгових обсягів

Для порівняльного аналізу торгових обсягів використано On-Balance Volume (OBV), Money Flow Index (MFI), Індикатор накопичення/розподілу та Механістичний підхід. На рис. 4.1 зображено ціну (Price) торгів обсяги (Volume) та індикатори на даних торгової пари BTC/USDT з 1 квітня по 1 вересня 2024 року.

OBV підтверджує тренди, відстежуючи кумулятивний обсяг, але менш точний для визначення умов перекупленості та перепроданості. Механістичний імпульс визначає моменти ринкового імпульсу, такі як різкий негативний імпульс у липні 2024 року, який сигналізує про сильні зміни ціни та обсягу, але може переоцінювати незначні коливання. MFI позначає умови перекупленості та перепроданості, як-от сигнал перекупленості в серпні 2024 року, що передбачає корекцію ціни, хоча він схильний до помилкових сигналів у тривалих трендах. Індикатор накопичення/розподілу виявляє розбіжності між ціною та обсягом, демонструючи послаблення купівельного тиску в середині липня.




Рис. 4.1 – Ціна, торгові обсяги та індикатори BTC/USDT з 1 квітня по 1 вересня 2024 року.

Для отримання даних з біржі Binance [146] використовувалась бібліотека CCXT [147], для підготовки даних та розрахунку індикаторів – Numpy [148] та Pandas [149]. Для візуалізації використано пакет Plotly [150].

#### 4.2 Адаптація механістичного підходу до аналізу ринку криптовалют

Для практичного застосування узагальненого моментуму ми можемо використовувати ковзні середні (1.1). Стратегія полягає у використанні двох ковзних середніх на часовому ряду узагальненого моментуму: швидка і повільна. Швидка ковзна має менший період, а повільна – більший. У випадку, коли швидка ковзна перетинає повільну ковзну знизу вгору – то це сигнал на покупку активу, а при перетині згори вниз – то це сигнал на продаж. На рис. 4.2 можна побачити графік ціни Bitcoin, швидку та повільну ковзні та точки купівлі і продажу активів. За період з 1 січня 2021 року по 1 січня 2022 було проведено шість торгових угод: 4 з прибутками і 2 зі збитками. Середній прибуток становить 5.6% на одну торгову угоду. Можна зробити висновок, що ковзні середні не встигають за зміною ціни. Отже необхідно адаптувати механістичний підхід, щоб зробити його більш реактивним до змін.

Експоненціальна ковзна середня (Exponential Moving Average, або ЕМА) – це ковзна середня, яка надає більшу вагу тим значенням часового ряду, які ближче до поточної точки розрахунку та меншу вагу тим значенням, що далі від поточної точки розрахунку. ЕМА швидше реагує на останні зміни в значеннях, ніж проста середня ковзна, для якої всі значення в часовому ряді мають однакову вагу.

Експоненціальна ковзна розраховується за наступною формулою (4.1):

$$EMA_t = \left( Value_t \cdot \left( \frac{smoothing}{1+p} \right) \right) + EMA_{t-1} \cdot \left( 1 - \left( \frac{smoothing}{1+p} \right) \right), \quad (4.1)$$

де *smoothing* – це параметр згладжування, *p* – період за який розраховуємо ковзну,  $Value_t$  – поточне значення часового ряду,  $EMA_t$  – попереднє значення ЕМА.




Рис. 4.2 – Ціна Bitcoin, інтервал 1 день, узагальнений моментум, швидка ковзна з періодом 2 тижня (штрихована лінія) та повільна ковзна з періодом 4 тижні (пунктирна лінія). Період моментуму - 4 тижні. Точки купівлі - трикутник вгору, а точки продажу - трикутник вниз

На рис. 4.3 можна побачити графік ціни Bitcoin, швидку та повільну експоненціальні ковзні та точки купівлі і продажу активів. За період з 1 січня 2021 року по 1 січня 2022 було проведено шість торгових угод: 5 з прибутками та 1 зі збитками. Середній прибуток становить 8.8% на одну торгову угоду.




Рис. 4.3 – Ціна Bitcoin, інтервал 1 день, узагальнений моментум, швидка експоненціальна ковзна з періодом 2 тижні (штрихована лінія) та повільна експоненціальна ковзна з періодом 4 тижні (пунктирна лінія). Період моментуму - 4 тижні. Точки купівлі - трикутник вгору, а точки продажу - трикутник вниз.

Результати тестування адаптованого механістичного підходу за допомогою ЕМА можна побачити в Таблиці 4.1.

Результати тестування адаптованого механістичного підходу за допомогою ЕМА

Моментум	Кількість прибуткових торгових угод	Кількість збиткових торгових угод	Середній прибуток на одну угоду (%)
Стандартний	4	2	5.6
Адаптований	5	1	8.8

Адаптований механістичний підхід (моментум) швидше реагує на зміни в ціні, а проведені тести демонструють більший середній прибуток та точність.

### **4.3 Порівняльне дослідження цінової та механістичної ковзних середніх з використанням причинно-наслідкового аналізу на історичних даних Біткоїна**

#### **4.3.1 Дані та ретроспективні тести**

Для тестування ковзних середніх історичні дані біткоїна були зібрані з лютого 2017 року по липень 2023 року, тобто 78 місяців. Інтервал часових рядів – 1 день. Ціна торгової пари BTC/USDT на момент закриття була використана для розрахунку ковзних середніх. Під час тестування прибутковість і точність ковзних середніх досліджувалися за допомогою стратегії перетину двох ковзних середніх: швидкої та повільної ковзних середніх. Прибутковість вимірюється як сума всіх відносних прибутків. Точність – це коефіцієнт виграшу ковзного середнього, який можна обчислити як суму всіх угод, поділену на суму прибуткових угод.

Для ковзних середніх обрано розміри комбінацій двох типів періодів: швидких і повільних періодів. Також один додатковий параметр для обчислення механістичної ковзної середньої (MSMA (2.5)), яка приймає значення найбільшого параметра повільної ковзної середньої. Параметри для швидких і повільних середніх значень є комбінаціями від 8 до 32 днів із кроком у два, з обмеженням, що швидке вікно має бути меншим за повільне. Таким чином, було застосовано 78 комбінацій параметрів для кожного типу ковзної середньої та проведено 156 бектестів. Додаткове значення для механічної ковзної середньої становило 32 дні для всіх комбінацій. Параметри періодів від 8 до 32 вибираються для оцінки короткострокових і середньострокових торгових стратегій на денному таймфреймі.

### 4.3.2 Тенденції прибутків та коефіцієнтів виграшу

Основні статистичні показники [151], які описують центральну тенденцію та дисперсію розподілу, розраховано як для MSMA, так і для доходів SMA, наведено в Таблиці 4.2: середнє значення прибутку, стандартне відхилення, мінімум, максимум і процентилі (25-й, медіана та 75-й). Ці показники дають змогу зрозуміти, як розподіляються прибутки та відносну нестабільність кожного підходу.

Таблиця 4.2

Прибутки цінової та механістичної ковзних середніх

Прибуток, %	MSMA	SMA
Кількість угод	6054	5098
Середнє значення	5.6	9.3
Стандартне відхилення	21.8	39.4
Мінімальне значення	-41.3	-39.1
25% процентиля	-4.5	-6.6
50% процентиля	0.4	-0.9
75% процентиля	8.1	7.0
Максимальне значення	151.5	282.2

MSMA демонструє нижче стандартне відхилення (21.8%) порівняно з SMA (39.4%), що свідчить про те, що MSMA дає більш стабільні прибутки з меншою волатильністю. Також MSMA має вужчий діапазон прибутків від 25-го до 75-го процентиля, що вказує на більш помірні прибутки порівняно з ширшим розподілом SMA. Медіана прибутку для SMA (-0.9%) нижча за її середнє значення (9.3%), що вказує на наявність надзвичайно високих позитивних прибутків, а максимальний прибуток (282.2%) на цьому ґрунті виглядає аномальним. Коефіцієнт виграшу,



наведений у Таблиці 4.3, описує відмінності між двома методами з точки зору частки угод, які закриті з прибутком із загальної кількості угод.

Таблиця 4.3

Коефіцієнт виграшу цінової та механістичної ковзних середніх

	Кількість угод	Середній коефіцієнт виграшу
MSMA	6054	52.2
SMA	5098	43.1

MSMA демонструє вищий коефіцієнт виграшу – 52.2%, а SMA – нижчий із коефіцієнтом виграшу 43.3%. Вищий коефіцієнт виграшу може бути важливим для інвесторів, які не схильні до ризику [152]. Однак варто зазначити, що нижчий коефіцієнт виграшу SMA за своєю суттю не означає низьку загальну прибутковість, оскільки він також може відображати інший профіль ризику та винагороди. SMA більш точний в отриманні вищих, хоча й рідших, прибутків.

Візуальне порівняння прибутковості комбінацій швидкої та повільної ковзних SMA та MSMA, представлене на теплових картах. Значення, представлені на малюнку, є відсотками, поділеними на 100. На тепловій карті прибутків (рис. 4.4) можна побачити, що більші розміри повільного вікна зазвичай дають вищі середні прибутки, особливо для SMA, а MSMA демонструє більш помірні середні прибутки зі значеннями, які зростають, але залишаються у вужчому діапазоні.




Рис. 4.4 – Теплова карта середніх прибутків для SMA та MSMA

Теплова карта суми прибутків (рис. 4.5) показує сумарні (кумулятивні) прибутки для кожного методу. Можна побачити, що кумулятивні прибутки SMA значно вищі за MSMA, хоч і менш однорідні.




Рис. 4.5 – Теплова карта кумулятивних прибутків для SMA та MSMA

Коефіцієнти виграшу представлено на рис. 4.6. Можна побачити, що MSMA демонструє вищі значення у більшому діапазоні періодів, з піковими показниками

близько 63%. Це спостереження узгоджується з попередніми, що MSMA має вищу загальну точність, і в цьому має перевагу в над SMA в різних конфігураціях.




Рис. 4.6 – Теплова карта коефіцієнтів виграшу для SMA та MSMA

Дані кореляції SMA (Таблиця 4.4) вказують на сильну позитивну кореляцію (0.87) між середньою (Сер.) прибутковістю та сумарною (Кум.) прибутковістю та дуже слабку кореляцію (0.1) між середньою прибутковістю та коефіцієнтом виграшу. Ці значення підтверджують попередні спостереження стосовно здатності SMA генерувати високі, але не часті прибутки.

Таблиця 4.4

Кореляція прибутку до коефіцієнту виграшу для SMA

	Сер. прибуток	Кум. прибуток	Коефіцієнт виграшу
Середній прибуток	1	0.87	0.1
Кумулятивний прибуток	0.87	1	0.21
Коефіцієнт виграшу	0.1	0.21	1

MSMA (Таблиця 4.5) демонструє слабшу позитивну кореляцію між середньою та кумулятивною прибутковістю (0.57), однак значно вищу кореляцію між середнім прибутком та коефіцієнтом виграшу (0.43). Це узгоджується з попередніми спостереженнями стосовно здатності MSMA мати вищу частку прибуткових угод.

Таблиця 4.5

Кореляція прибутку до коефіцієнту виграшу для MSMA

	Сер. прибуток	Кум. прибуток	Коефіцієнт виграшу
Середній прибуток	1	0.57	0.43
Кумулятивний прибуток	0.57	1	0.35
Коефіцієнт виграшу	0.43	0.35	1

### 4.3.3 Аналіз розподілів

Розподіли прибутків для MSMA (рис. 4.7) більш стиснуті у порівнянні з SMA. Також, розподіл SMA містить значну кількість аномальних прибутків. Візуальний аналіз розподілів узгоджується з попередніми спостереженнями профілю прибутковості MSMA та SMA.

Two-sample t-test – це метод, який використовується для перевірки того, чи схожі невідомі середні генеральних сукупностей двох груп [153]. Проведено два two-sample t-test, щоб перевірити статистичні відмінності між SMA та MSMA: різницю в середній прибутковості та коефіцієнтах виграшу (Таблиця 4.6).




Рис. 4.7 – Розподіли прибутків для SMA та MSMA

Результати t-тесту можуть вказувати на статистично значущу різницю між SMA та MSMA як у середній прибутковості, так і в коефіцієнтах виграшу. Спостережувані відмінності навряд чи виникли випадково та справді відображають різні моделі поведінки SMA та MSMA.

Таблиця 4.6

Т-тести середньої прибутковості та коефіцієнту виграшу

	р-значення
Середній прибуток	$4.05 \times 10^{-10}$
Коефіцієнт виграшу	$1.13 \times 10^{-21}$

#### 4.3.4 Напрямок тренду та прибутки

Аналіз середньо-тижневої прибутковості SMA (рис. 4.8) і MSMA (рис. 4.9) показує, що прибутки нерівномірно розподіляються в різних ринкових режимах, причому обидва методи демонструють вищу прибутковість під час періодів висхідного тренду порівняно з низхідним трендом.




Рис. 4.8 – Щотижнева середня прибутковість SMA за висхідними та спадними трендами Біткоїна




Рис. 4.9 – Щотижнева середня прибутковість MSMA за висхідними та спадними трендами Біткоїна

SMA має більш екстремальні прибутки завдяки значному зростанню ціни під час яскраво виражених трендів (у 2018, 2019 та 2021 роках), а MSMA має більш стабільні прибутки в обох ринкових умовах, з меншою прибутковістю, але більшою точністю, ніж SMA. Також MSMA має вищі негативні збитки, ніж SMA.

#### 4.3.5 Причинно-наслідковий ефект використання MSMA на прибутки

Для оцінки ефекту SMA порівняно з MSMA та їхньої відповідної змінної прибутку, “Method” використовувався як Treatment змінна для розрізнення використання двох різних методів ковзного середнього, а “Return” використовувався як Outcome змінна для вимірювання прибутковості. Причинно-наслідкові зв'язки для оцінки ефекту SMA порівняно з MSMA до прибутків можна виразити через (4.2):

$$\frac{d}{d(\text{Method})} \cdot E(\text{Return} \mid \text{confounders}), \quad (4.2)$$

де змішаними змінними (confounders) є змінні “slow\_period”, “fast\_period”, “year” і “month”; змінна Treatment – “Method” та Outcome – “Return”.

Причинно-наслідковий аналіз методів SMA та MSMA було проведено, щоб визначити, чи існує причинно-наслідковий ефект між вибором методу та спостережуваними прибутками від торгівлі. Результати в Таблиці 4.7 показують, що всі три методи свідчать про негативний причинно-наслідковий ефект використання MSMA порівняно з SMA, причому розрахункові значення ATE коливаються від -3,5% до -6,0%. Це свідчить про те, що в середньому використання MSMA призводить до нижчої прибутковості, що узгоджується спостережуваним відмінностям у меншій середній прибутковості MSMA відносно SMA.

Таблиця 4.7

Ефект за метриками ATE, ATT та ATC від використання MSMA

Метод	ATE, %	ATT, %	ATC, %
PSM	-5.9	-5.7	-6.0
PSS	-3.5	-3.5	-3.6
DML	-4.0	-4.0	-3.9

Щоб перевірити ці оцінки, було проведено кілька тестів на спростування як показано в Таблиці 4.8. Дві моделі пройшли кожен із цих тестів, за винятком DML, яка не пройшла тест плацебо.

Таблиця 4.8

Тести на спростування причинно-наслідкових моделей

Модель	RCC	PTR	DSR
PSM	Успіх	Успіх	Успіх
PSS	Успіх	Успіх	Успіх
DML	Успіх	Невдача	Успіх

#### 4.3.6 Причинно-наслідковий ефект напрямку тренду на прибутки для MSMA

Щоб оцінити вплив напрямків тренду та відповідної їм прибутковості, змінну “global\_trend\_flag” використовували як Treatment змінну для розрізнення тестування під час висхідного та спадного трендів, а “Return” використовували як Outcome змінну для вимірювання прибутковості. Причинно-наслідкові зв'язки можна виразити через (4.3):

$$\frac{d}{d(\text{global trend flag})} \cdot E(\text{Return} \mid \text{confounders}), \quad (4.3)$$

де змішаними змінними (confounders) є змінні “slow\_period”, “fast\_period”, “year” і “month”; змінна Treatment – “global\_trend\_flag” та Outcome – “Return”.

Для визначення висхідного та спадного трендів використовувався одновимірний фільтр Гауса [154] через (4.4)

$$g(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{\frac{-x^2}{2\sigma^2}}, \quad (4.4)$$

де  $\sigma$  – стандартне відхилення, а  $x$  – значення часового ряду.

Результати, наведені в таблиці 4.9, вказують на те, що використання MSMA позитивно корелює з вищою прибутковістю під час висхідних трендів, що свідчить



про причинно-наслідковий зв’язок між напрямком тренду та прибутковістю. Щоб перевірити надійність цих причинних оцінок, було застосовано три тести на спростування (Таблиця 4.10). Дві моделі пройшли кожен із цих тестів, за винятком DML, який не пройшов перевірку плацебо.

Таблиця 4.9

Ефект за метриками АТЕ, АТТ та АТС від напрямку тренду

Метод	АТЕ, %	АТТ, %	АТС, %
PSM	17.5	16.7	18.3
PSS	16.4	15.8	17.2
DML	16.3	16.2	16.1

Таблиця 4.10

Тести на спростування причинно-наслідкових моделей

Модель	RCC	PTR	DSR
PSM	Успіх	Успіх	Успіх
PSS	Успіх	Успіх	Успіх
DML	Успіх	Невдача	Успіх

Аналіз показує, що MSMA дає значно вищу прибутковість у висхідних трендах, з оціненим середнім прибутком приблизно на 16% порівняно з низхідними трендами.

**4.4 Експериментальна валідація та оцінювання точності удосконаленого методу механістичного аналізу динаміки криптовалютних активів**

**4.4.1 Дані та ретроспективні тести**

Історичні дані торгів пари біткоїна до стейблкоїна USDT були отримані з біржі Binance за період з січня 2019 року по січень 2025 року. Досліджувались наступні часові інтервали: 1-денний, 4-годинний та 30-хвилинний. Застосована стратегія ковзних середніх, щоб дослідити відмінності в результатах застосування

узагальненого імпульсу сумарних обсягів (GMI Volume) до нових розроблених методів:

- 1) узагальненого імпульсу обсягів покупок (GMI Volume Buy);
- 2) узагальненого імпульсу обсягів продажів (GMI Volume Sell);
- 3) узагальненого імпульсу абсолютної різниці обсягів покупок та продажів (GMI Volume Delta Abs).

Стратегія ковзних середніх передбачає налаштування двох ковзних: швидка ковзна (10-денний або 50-денний періоди) та повільна ковзна (50-денний або 200-денний періоди). Коли швидка ковзна перетинає повільну знизу вгору, це сигналізує про потенційний висхідний тренд (Long). І навпаки, коли швидка ковзна перетинає повільну з гори вниз, це сигналізує про потенційний спадний тренд (Short).

Усього проведено 2028 тестувань: по 676 тестів для 30-хвилинного, 4-годинного та 1-денного інтервалів. Де 676 тест це комбінації механістичного періоду та періоду повільної ковзної з періодом 14 до 64, де швидка механістична ковзна завжди має період вдвічі менший за повільну.

Прибутковість вимірюється як сума всіх відносних прибутків з кожної угоди, тобто розрахунки проводяться на “чистих” прибутках без врахування складного відсотка. Точність – це коефіцієнт виграшу ковзного середнього, який можна обчислити як суму всіх угод, поділену на суму прибуткових угод.

Тестування за допомогою стратегії перетину ковзних середніх є суто алгоритмічним та не враховує процесів ухвалення рішень аналітиком перед тим як відкрити або закрити угоду, однак цей підхід є простим, зрозумілим та дає загальне розуміння точності розроблених методів. Стратегія “купи та тримай” (buy and hold) була застосована для порівняння точності тестування не тільки між розробленими методами та узагальненим імпульсом сумарних обсягів, але й з базовою стратегією (baseline strategy).

#### **4.4.2 Результати ретроспективних тестувань**

На рис. 4.10 зображено теплову карту сум прибутків, а на рис. 4.11 теплову карту коефіцієнту виграшу на інтервалі в 1 день для узагальненого імпульсу сумарних

обсягів (GMI Volume), узагальненого імпульсу обсягів покупок (GMI Volume Buy), узагальненого імпульсу обсягів продажів (GMI Volume Sell) та узагальненого імпульсу абсолютної різниці обсягів покупок та продажів (GMI Volume Delta) на даних торгової пари BTC/USDT. У таблиці 4.11 наведено мінімальні (min), медіанні (median), середні (mean) та максимальні (max) сумарні прибутки, а в таблиці 4.12 мінімальні, медіанні, середні та максимальні коефіцієнти виграшу.




Рис. 4.10 – Теплова карта сумарних прибутків (Total Return Sum [%]) на інтервалі 1 день

Таблиця 4.11

Сумарні прибутки для інтервалу 1 день у відсотках (%)

%	GMI Volume	GMI Volume Delta	GMI Volume Buy	GMI Volume Sell
Min	160.1	144.3	200.1	165.1
Mean	320.9	292.4	322.1	320.2
Median	317.8	291.1	318.6	314.5
Max	507.4	490.1	479.9	493.4

Таблиця 4.12

Коефіцієнти виграшу для інтервалу 1 день у відсотках (%)

%	GMI Volume	GMI Volume Delta	GMI Volume Buy	GMI Volume Sell
Min	34.9	29.4	34.6	35.3
Mean	50.1	46.3	50.6	50.2
Median	50	46.4	50	50
Max	62.5	65.5	64.7	64.7




Рис. 4.11 – Теплова карта коефіцієнту виграшу (Win Rate [%]) на інтервалі 1 день

Імпульс обсягів покупок демонструє найвищі середні (322.1%), медіанні (318.6%) та мінімальні (200.1%) сумарні прибутки у порівнянні з усіма іншими імпульсами. Імпульс різниці обсягів демонструє найнижчі середні (292.4%) та медіанні (291.1%) сумарні прибутки. Інша ситуація з коефіцієнтами виграшу, де імпульс різниці демонструє найнижчі показники, такі як середнє (46.3%) та мінімальне (29.4%), а інші імпульси мають відносно однакові значення середніх та медіанних прибутків з невеликою перевагою імпульсу покупок. Імпульс сумарних обсягів має найменше максимальне значення (62.5%). Графіки розподілів на рис. 4.12 підтверджують тенденції зображені на теплових картах.




Рис. 4.12 – Розподіли прибутків (Total Return Sum [%]) та коефіцієнтів виграшу (Win Rate [%]) на інтервалі 1 день

На рис. 4.13 зображено теплову карту сум прибутків, а на рис. 4.14 теплову карту коефіцієнту виграшу на інтервалі в 4 години для узагальнених імпульсів на даних торгової пари BTC/USDT. У таблиці 4.13 наведено мінімальні (min), медіанні (median), середні (mean) та максимальні (max) сумарні прибутки, а в таблиці 4.14 мінімальні, медіанні, середні та максимальні коефіцієнти виграшу. Імпульс обсягів покупок демонструє найвищі середні (336.8%) та медіанні (337.9%) сумарні прибутки, в той час як імпульс різниці обсягів найменші середні (317.2%) та медіанні (324.6%) значення. Графіки розподілів на рис. 4.15 підтверджують тенденції зображені на теплових картах.

Таблиця 4.13

Сумарні прибутки для інтервалу 4 години у відсотках (%)

%	GMI Volume	GMI Volume Delta	GMI Volume Buy	GMI Volume Sell
Min	141.6	131.35	125.5	147.3
Mean	333.4	317.2	336.8	331.6
Median	333.6	324.6	337.9	333.4
Max	466.4	481.7	468.9	460.4

Коефіцієнти виграшу для інтервалу 4 години у відсотках (%)

%	GMI Volume	GMI Volume Delta	GMI Volume Buy	GMI Volume Sell
Min	36.7	36.5	37.5	36.2
Mean	43.4	43.1	43.6	43.3
Median	43.4	43.2	43.7	43.3
Max	51.2	49.1	50	50




Рис. 4.13 – Теплова карта сумарних прибутків (Total Return Sum [%]) на інтервалі 4 години




Рис. 4.14 – Теплова карта коефіцієнту виграшу (Win Rate [%]) на інтервалі 4 години




Рис. 4.15 – Розподіли прибутків (Total Return Sum [%]) та коефіцієнтів виграшу (Win Rate [%]) на інтервалі 4 години

На рис. 4.16 зображено теплову карту сум прибутків, а на рис. 4.17 теплову карту коефіцієнту виграшу на інтервалі в 30 хвилин для узагальнених імпульсів на



даних торгової пари BTC/USDT. У таблиці 4.15 наведено мінімальні (min), медіанні (median), середні (mean) та максимальні (max) сумарні прибутки, а в таблиці 4.16 мінімальні, медіанні, середні та максимальні коефіцієнти виграшу.




Рис. 4.16 – Теплова карта сумарних прибутків (Total Return Sum [%]) на інтервалі 30 хвилин

Таблиця 4.15

Сумарні прибутки для інтервалу 30 хвилин у відсотках (%)

%	GMI Volume	GMI Volume Delta	GMI Volume Buy	GMI Volume Sell
Min	-241.3	-340.9	-253.1	-216.3
Mean	238.5	202.1	239.5	236.1
Median	282.8	252.6	285.1	279.6
Max	452.1	463.9	457.3	475.4

Коефіцієнти виграшу для інтервалу 30 хвилин у відсотках (%)

%	GMI Volume	GMI Volume Delta	GMI Volume Buy	GMI Volume Sell
Min	34.4	34.8	34.4	34.1
Mean	37.9	37.9	38.2	37.9
Median	38.2	37.9	38.3	37.8
Max	41.4	41.2	41.2	41.4

У всіх імпульсах з'явилися збитки, де найбільш збитковим є імпульс різниці обсягів (-340.9%). Імпульс обсягів покупок має найбільші середні (239.5%) та медіанні (285.1%) сумарні прибутки. За коефіцієнтами виграшу імпульс обсягів також має найбільші значення середнього (38.2%) та медіанного (38.3%). Графіки розподілів на рис. 4.18 підтверджують тенденції зображені на теплових картах.



Рис. 4.17 – Теплова карта коефіцієнту виграшу (Win Rate [%]) на інтервалі 30  
ХВИЛИН




Рис. 4.18 – Розподіли прибутків (Total Return [%]) та коефіцієнтів виграшу (Win Rate [%]) на інтервалі 30 хвилин

Імпульс різниці обсягів продемонстрував найнижчі показники прибутків та коефіцієнтів виграшу на всіх таймфреймах, а розподіли прибутків є найменш стабільними з більшою кількістю аномальних мінімальних та максимальних значень. Цілком має сенс розглядати використання імпульсу різниці обсягів як показник, що може підказати чи потенційна угода є більш ризиковою, якщо ми одночасно отримали сигнал на покупку від цього індикатора та сигнал на покупку від інших імпульсів обсягів. У випадку ж сигналу тільки від імпульсів покупки чи продажів без сигналу від різниці обсягів може вказувати на менш ризикову угоду. Імпульс обсягів покупок продемонстрував найвищі значення сумарних прибутків та коефіцієнтів виграшу на всіх інтервалах. Імпульси обсягів продажів та сумарних обсягів продемонстрували схожі результати, з невеликою перевагою останнього в значеннях прибутковості та коефіцієнта виграшу. Виявлено, що зі зменшенням інтервалу зменшується коефіцієнт виграшу для всіх імпульсів, а також сумарні прибутки. Також для 30-хвилинного інтервалу почали з'являтися збитки, яких не було зафіксовано для денного та 4-годинного інтервалів. Виявлено, що зі зменшенням інтервалу збільшується чутливість до вибору механістичного та ковзного періодів, які впливають на потенційну прибутковість.

Прибутковість стратегії “купи та тримай” (buy and hold) –1452.8%, що вище за будь-який імпульс обсягів, однак необхідно врахувати, що ця стратегія має тільки одну покупку, і як наслідок унеможливорює активу роботу з портфолію активів та його ребалансування.

## **4.5 Експериментальна валідація та оцінювання точності показника поглинання імпульсу**

### **4.5.1 Дані та ретроспективні тести**

Історичні дані торгів пари біткоїна до стейблкоїна USDT були отримані з біржі Binance за період з січня 2019 року по січень 2025 року. Досліджувались наступні часові інтервали: 1-денний, 4-годинний та 30-хвилинний. Проведено тестування 5 показників поглинання імпульсу:

- 1)  $MAS_{V,t}$  – сумарні ринкові обсяги (3.15);
- 2)  $MAS_{buy\ VD,t}$  – різниця ринкових обсягів покупок (3.16);
- 3)  $MAS_{sell\ VD,t}$  – різниця ринкових обсягів продажів (3.17);
- 4)  $MAS_{buy\ VB,t}$  – співвідношення покупок до сумарних обсягів (баланс покупок) (3.18);
- 5)  $MAS_{sell\ VB,t}$  – співвідношення продажів до сумарних обсягів (баланс продажів) (3.19).

Використання показників поглинання імпульсу має бути складовою комплексного аналізу різних факторів та процесів, які можуть впливати на ціну активу. Оскільки дослідження не передбачає розробку складної та багатокомпонентної стратегії торгівлі з урахуванням великої кількості факторів, було прийнято рішення застосувати дві прості алгоритмічні стратегії, які можуть наближено оцінити прибутковість розроблених показників поглинання імпульсу:

- 1) Базова стратегія (Basic Strategy): стратегія аномального відхилення ціни;
- 2) Покращена стратегія (Improved Strategy): стратегія наближення до оптимального закриття угоди.

Кожна стратегія оцінювала показники поглинання імпульсу за допомогою двох типів позицій:

1) довга позиція (long position) – відкриття угоди на покупку з метою продати актив дорожче за початкову ціну;

2) коротка позиція (short position) – відкриття угоди на продаж (шляхом позичення коштів у, наприклад, біржі) з метою купити актив дешевше за початкову ціну (повернути позику біржі та забрати прибуток від падіння ціни активу).

Базова стратегія передбачає:

1) відкриття довгої позиції, коли отримано позитивне значення показника поглинання імпульсу та z-показник відхилення ціни нижчий за 25 процентиль для останніх 30 значень ціни;

2) закриття довгої позиції, коли z-показник відхилення ціни вищий за 75 процентиль для останніх 30 значень ціни;

3) відкриття короткої позиції, коли отримано позитивне значення показника поглинання імпульсу та z-показник відхилення ціни вищий за 75 процентиль для останніх 30 значень ціни;

4) закриття короткої позиції, коли z-показник відхилення ціни нижчий за 25 процентиль для останніх 30 значень ціни.

У підсумковій таблиці 4.17 наведено правила базової стратегії, де MAS – це будь-який показник поглинання імпульсу, а Z-показник – це стандартне відхилення ціни активу.

Таблиця 4.17

Правила базової стратегії

Позиція	Дія	MAS	Z-показник < 25	Z-показник > 75
Довга	Відкриття	1	Так	Ні
Довга	Закриття	1 або 0	Ні	Так
Коротка	Відкриття	1	Ні	Так
Коротка	Закриття	1 або 0	Так	Ні

Покращена стратегія (або ж стратегія наближення до оптимального закриття угоди) – полягає у застосуванні гаусівського згладжування ціни активу на всьому доступному діапазоні часового ряду (4.4). Таку згладжену ціну можна використати для визначення зон близьких до локальних максимумів та мінімумів. Однак цю стратегію неможливо відтворити в умовах реальної ринкової торгівлі, коли майбутня ціна активу невідома, бо цей метод згладжування застосований на всіх значеннях часового ряду (тобто не є ковзною функцією). Мета цієї стратегії – імітувати складну систему прийняття рішень, яка може генерувати набагато точніші закриття угоди, аніж базова стратегія. Однак імітування відбувається за допомогою отримання інформації про майбутні значення цін відносно поточних. На рис. 4.19 зображено приклад локальних екстремумів: максимуми (червоні стрілки) та мінімуми (зелені стрілки) згладженої ціни (Smoothed price). Значення згладженої ціни використовується як ціна закриття позиції: локальний мінімум для закриття короткої позиції та локальний максимум для закриття довгої позиції.



Рис. 4.19 – Максимуми (червоні стрілки) та мінімуми (зелені стрілки) згладженої ціни (Smoothed price)

Отже, сформуємо припущення, що у випадку застосування показників поглинання імпульсу в складних системах прийняття рішень, ми можемо орієнтуватися на результати цієї стратегії. Покращена стратегія передбачає:

1) відкриття довгої позиції, коли отримано позитивне значення показника поглинання імпульсу та z-показник відхилення ціни нижчий за 25 перцентиль для останніх 30 значень ціни;

2) закриття довгої позиції, коли згладжена ціна досягла локального максимуму;

3) відкриття короткої позиції, коли отримано позитивне значення показника поглинання імпульсу та z-показник відхилення ціни вищий за 75 перцентиль для останніх 30 значень ціни;

4) закриття короткої позиції, коли згладжена ціна досягла локального мінімуму.

У підсумковій таблиці 4.18 наведено правила покращеної стратегії, де MAS – це будь-який показник поглинання імпульсу, Z-показник – це стандартне відхилення ціни активу, а Local Max та Local Min – це локальний максимум та локальний мінімум згладженої ціни відповідно.

Таблиця 4.18

## Правила покращеної стратегії

Позиція	Дія	MAS	Z-score < 25	Z-score > 75	Local Max	Local Min
Довга	Відкриття	1	Так	Ні	–	–
Довга	Закриття	1 або 0	–	–	1	–
Коротка	Відкриття	1	Ні	Так	–	–
Коротка	Закриття	1 або 0	–	–	–	1

Прибутковість вимірюється як сума всіх відносних прибутків з кожної угоди, тобто розрахунки проводяться на “чистих” прибутках без врахування складного відсотка. Точність – це коефіцієнт виграшу, який можна обчислити як суму всіх угод, поділену на суму прибуткових угод. Результати MAS порівнюються з двома технічними індикаторами: VWAP (1.9) та GMI (2.1). Стратегію перетину швидкої та

повільної ковзних середніх використано для тестування цих двох показників. Коли швидка ковзна середня перетинає повільну знизу вгору, це сигналізує про відкриття довгої позиції та закриття короткої. І навпаки, коли швидка ковзна середня перетинає повільну з гори вниз, це сигналізує про закриття довгої позиції та відкриття короткої.

Також, з метою прискорення часу обчислення Показників поглинання імпульсу застосовано методи динамічної компіляції (ЛТ-компіляції) та кешування. Це дозволило перетворювати алгоритми обробки часових рядів у машинний код безпосередньо перед виконанням. Тестування показали стабільну перевагу оптимізованого методу. Наприклад, на вибірці в 1000000 записів стандартний підхід потребував ~2.0 секунди, тоді як оптимізований метод із застосуванням ЛТ та паралелізації впорався за ~0.6 секунди (рис. 4.20).




Рис. 4.20 – Порівняння швидкості обчислень для Стандартного та Оптимізованого методів

#### 4.5.2 Результати ретроспективних тестувань

На рис. 4.21 зображено середні прибутки для VWAP, GMI та базової стратегії MAS показників: MAS Volume, MAS Buy Volume Delta, MAS Sell Volume Delta, MAS Buy Volume Balance та MAS Sell Volume Balance. Можна побачити, що:



1) VWAP має набагато вищі середні прибутки на денному інтервалі серед усіх індикаторів, але на 4 годинах та 30 хвилинах середні прибутки не виділяються суттєво;

2) тільки MAS балансу обсягів (MAS Buy Volume Balance та MAS Sell Volume Balance) в середньому мають прибутки, а інші MAS показники збиткові;

3) на 30 хвилинному інтервалі тільки GMI в середньому збитковий.




Рис. 4.21 – Середні прибутки VWAP, GMI та базової стратегії MAS показників

На рис. 4.22 зображено сумарні прибутки для VWAP, GMI та базової стратегії MAS показників. Можна побачити, що:

1) VWAP має найвищі сумарні прибутки на денному та 30 хвилинному інтервалах;

2) GMI має найвищі сумарні прибутки на 4 годинному інтервалі, однак дуже великі збитки на 30 хвилинному інтервалі;

3) MAS показники в більшості збиткові на денному інтервалі, однак прибуткові на 4 годинному та 30 хвилинному.




Рис. 4.22 – Сумарні прибутки VWAP, GMI та базової стратегії MAS показників

На рис. 4.23 зображено коефіцієнти виграшу для VWAP, GMI та базової стратегії MAS показників. Можна побачити, що в VWAP та GMI помітно нижчі коефіцієнти виграшу, аніж MAS, однак MAS показники на денному інтервалі мають нижчі коефіцієнти виграшу, аніж на 4 годинному та 30 хвилинному інтервалах.




Рис. 4.23 – Коефіцієнти виграшу VWAP, GMI та базової стратегії MAS показників

Загалом, MAS показники поступаються VWAP та GMI у сумарних прибутках, однак не в коефіцієнтах виграшу. Підраховано кількість згенерованих показників поглинання імпульсу нижче процентиля 25 (Below Lower Bound) та вище процентиля 75 (Above Lower Bound) для: сумарний обсяг (Volume), різниця обсягів покупок (Buy

Volume Delta), різниця обсягів продажів (Sell Volume Delta), баланс покупок (Buy Volume Balance) та баланс продажів (Sell Volume Balance). На рис. 4.24 зображено кількість показників на 1-денному інтервалі, на рис. 4.25 на 4-годинному інтервалі та на рис. 4.26 на 30-хвилинному інтервалі.




Рис. 4.24 – Кількість показників поглинання імпульсу нижче процентиля 25 та вище процентиля 75 для 1-денного інтервалу




Рис. 4.25 – Кількість показників поглинання імпульсу нижче процентиля 25 та вище процентиля 75 для 4-годинного інтервалу




Рис. 4.26 – Кількість показників поглинання імпульсу нижче процентиля 25 та вище процентиля 75 для 30-хвилинного інтервалу

Можна побачити, що на всіх інтервалах простежуються наступні закономірності:

1) кількість значень вище процентиля 75 більше, ніж кількість значень нижче процентиля 25. Це може вказувати на те, що кількість коротких позицій, відповідно до правил базової стратегії, більше, ніж довгих;

2) найбільшу кількість значень має показник балансу покупок;

3) найменшу кількість значень має показник сумарних обсягів;

4) показники балансу покупок та балансу продажів мають більшу кількість значень, ніж показники різниці обсягів покупок та продажів. Це може вказувати на те, що кількість дисбалансів у відносних величинах більша за кількість дисбалансів в абсолютних.

На рис. 4.27 зображено середні прибутки базової (Basic) та покращеної (Improved) стратегій на 1-денному, 4-годинному та 30-хвилинному інтервалах. Аналогічно на рис. 4.28 зображено сумарні прибутки, а на рис. 4.29 коефіцієнти виграшу.




Рис. 4.27 – Середні прибутки базової (Basic) та покращеної (Improved) стратегій на 1-денному, 4-годинному та 30-хвилинному інтервалах




Рис. 4.28 – Сумарні прибутки базової (Basic) та покращеної (Improved) стратегій на 1-денному, 4-годинному та 30-хвилинному інтервалах




Рис. 4.29 – Коефіцієнти виграшу базової (Basic) та покращеної (Improved) стратегій на 1-денному, 4-годинному та 30-хвилинному інтервалах

Можна побачити, що на всіх інтервалах простежуються наступні закономірності:

- 1) Базова стратегія прибуткова для більшості показників;
- 2) Покращена стратегія генерує більше прибутків та є більш точною за базову стратегію;
- 3) показник сумарних обсягів генерує збитки для 1-денного та 4-годинного інтервалів. Однак 30-хвилинний інтервал прибутковий із середнім прибутком вищим за інші показники, але сумарні прибутки не відрізняються суттєво для базової стратегії;
- 4) інтервал 30 хвилин має більші сумарні прибутки для обох стратегій;
- 5) інтервал 30 хвилин має менші коефіцієнти точності для базової стратегії, але більші для покращеної у порівнянні з 4-годинним інтервалом;
- 6) у більшості випадків показник поглинання імпульсу різниці обсягів продажів має найменші середні та сумарні прибутки;
- 7) інтервал 1 день є менш прибутковим та точним.

Отже, чим менший інтервал, тим менший середній прибуток, але більший сумарний прибуток за рахунок більшої кількості угод. А показники поглинання імпульсу балансу та різниці обсягів більш прибуткові, аніж сумарні обсяги.

В таблиці 4.19 зображено 30-хвилинний інтервал та середні прибутки (Сер. прибуток) в розрізі довгої (Long) та короткої (Short) позицій для Сумарний обсяг (Volume), різниця покупок (VD Buy), різниця продажів (VD Sell), баланс покупок (VB Buy) та баланс продажів (VB Sell).

Таблиця 4.19

30-хвилинний інтервал та середні прибутки в розрізі довгої та короткої позицій

Стратегія	Показник	Загальний Сер. прибуток, %	Сер. прибуток довга позиція, %	Сер. прибуток коротка позиція, %
Базова	Volume	0.33	0.28	0.36
Покращена	Volume	0.93	0.96	0.91
Базова	VD Buy	0.15	0.32	0.07
Покращена	VD Buy	0.76	0.92	0.68
Базова	VD Sell	0.07	0.13	0.04
Покращена	VD Sell	0.68	0.76	0.64
Базова	VB Buy	0.1	0.25	0.03
Покращена	VB Buy	0.69	0.84	0.61
Базова	VB Sell	0.12	0.18	0.09
Покращена	VB Sell	0.73	0.81	0.68

Можна побачити чітку закономірність, що для всіх показників та обох стратегій середні прибутки довгої позиції більші, аніж середні прибутки короткої. Лише один

виняток – це сумарні обсяги базової стратегії, де середній прибуток короткої позиції вищий за довгу.

Подібні висновки про більшу середню прибутковість довгих позицій можна зробити за результатами тестувань для 1-денного (таблиця 4.20) та 4-годинного (таблиця 4.21) інтервалів.

Таблиця 4.20

1-денний інтервал та середні прибутки в розрізі довгої та короткої позицій

Стратегія	Показник	Загальний Сер. прибуток, %	Сер. прибуток довга позиція, %	Сер. прибуток коротка позиція, %
Базова	Volume	-11.12	-12.09	-10.15
Покращена	Volume	-0.19	9.76	-10.15
Базова	VD Buy	-2.76	-1.56	-3.5
Покращена	VD Buy	3.67	5.7	2.35
Базова	VD Sell	-0.32	-2.57	1.42
Покращена	VD Sell	2.5	3.33	1.85
Базова	VB Buy	0.73	2.28	-0.53
Покращена	VB Buy	2.86	4.32	1.71
Базова	VB Sell	1.86	2.84	1.16
Покращена	VB Sell	2.2	4.38	0.53

У випадку з 1-денним інтервалом тільки два показника мають середні прибутки кротких позицій більші, аніж довгих: базові стратегії сумарних обсягів та різниці обсягів продажів.



Таблиця 4.21

4-годинний інтервал та середні прибутки в розрізі довгої та короткої позицій

Стратегія	Показник	Загальний Сер. прибуток, %	Сер. прибуток довга позиція, %	Сер. прибуток коротка позиція, %
Базова	Volume	-0.82	-0.75	-0.88
Покращена	Volume	0.62	3.07	-1.02
Базова	VD Buy	0.37	1.44	-0.42
Покращена	VD Buy	2.45	3.21	1.9
Базова	VD Sell	0.52	0.8	0.38
Покращена	VD Sell	1.95	2.43	1.71
Базова	VB Buy	0.46	1.96	-0.55
Покращена	VB Buy	2.63	3.55	2.01
Базова	VB Sell	0.54	0.77	0.4
Покращена	VB Sell	1.97	2.12	1.88

У випадку з 4-годинним інтервалом усі показники мають більші середні прибутки для довгих позицій, аніж для коротких.

## 4.6 Експериментальна валідація та оцінювання точності удосконаленого методу прогнозування динаміки ринку криптовалют

### 4.6.1 Дані та конфігурація моделювання

Історичні дані топ 5 криптовалют (окрім стейблкоїнів) за ринковою капіталізацією (станом на 1 травня 2025 року), були отримані з біржі Binance за період з січня 2019 року по січень 2025 року: BTC/UDST, ETH/USDT, XRP/USDT, BNB/USDT, DOGE/USDT. Досліджувались наступні часові інтервали: 2-годинний, 1-годинний та 30-хвилинний. Часові інтервали вищі за 2-годинний (такі як 4-години або 1 день) вирішено не залучати, оскільки вони генерували недостатню кількість подій, що заважало оцінити точність моделей в контексті ковзної валідації. Інтервали нижчі за 30 також вирішено не залучати, оскільки вони вимагали значно більше обчислювальних потужностей, яких не було в доступі на момент дослідження. Вузький діапазон розглянутих інтервалів є ключовим обмеженням цього дослідження. Досліджено як довгі (Long) так і короткі (Short) позиції, де конфігурація методу трьох бар'єрів наступна:

- 1) бар'єр прибутку: 16 стандартних відхилень за останні 128 інтервалів;
- 2) бар'єр стоп-втрат: 8 стандартних відхилень за останні 128 інтервалів;
- 3) часовий бар'єр: 128 інтервалів.

Варто зауважити, що для довгої позиції бар'єр прибутку знаходиться вище ціни входу, а стоп-втрат нижче. Для короткої позиції бар'єр прибутку нижчий за ціну входу, а стоп-втрат вищий.

Усього застосовано 5 показників, з яких 3 це методи механістичного підходу:

- 1) механістична ковзна загального ринкового обсягу;
- 2)  $MAS_{buy\ VD,t}$  – різниця ринкових обсягів покупок (3.16);
- 3)  $MAS_{sell\ VD,t}$  – різниця ринкових обсягів продажів (3.17).

Та 2 показника ринкових обсягів для порівняння з механістичним підходом: MFI (1.3) та VWAP (1.9).

Сигнали на покупку для Механістичної ковзної та VWAP з'являються тоді, коли швидка ковзна перетинає повільну ковзну з низу на ногу, а на продаж (шорт), коли

швидка ковзна перетинає повільну з гори вниз. При цьому VWAP фактично стає VWMA (Volume Wighted Moving Average), що буде використовуватися далі в дослідженні. Для MAS сигнали на покупку з'являються тоді, коли значення показника 1, та стандартне відхилення ціни нижче 25 процентиля, а на продаж (шорт), коли значення 1, а стандартне відхилення ціни вище 75 процентиля. Для MFI сигнали на покупку з'являються тоді, коли значення індикатора нижче 10 процентиля, а на продаж (шорт), коли значення індикатора вище 90 процентиля. Для всіх індикаторів застосовувались наступні вікна: 16, 32, 64, та 128. Тобто загалом 20 варіацій показників з різними вікнами.

Застосовано 5 основних алгоритмів машинного навчання та один “Dummy” класифікатор, який генерує всі прогнози одним єдиним класом: “1” для довгих позицій та “-1” для коротких. Цей класифікатор служить простою основою для порівняння з іншими, складнішими класифікаторами. Застосовані алгоритми наступні: Dummy, Summary, Catch22, Rocket, TimeCNN та Stacking. Усі шість алгоритмів провалідовано за допомогою ковзної валідації.

#### **4.6.2 Результати валідації моделей машинного навчання**

На рис. 4.30 зображено розподіли ключових метрик моделей агреговані для всіх торгових пар, таймфреймів та сигналів для довгих позицій (зелений колір) та коротких позицій (червоний колір). Можна побачити, що розподіли для Dummy класифікатора суттєво відрізняються від усіх інших моделей. Це пов'язано з тим, що ця модель генерує лише одне значення прогнозу: “1” для довгих позицій та “-1” для коротких. Тому Roc-Auc Score завжди 0.5, а Recall завжди 1.0, оскільки Dummy класифікатор для кожного сигналу завжди генерує одне й те саме значення, тобто кількість хибно негативних значень дорівнює нулю.




Рис. 4.30 – Метрики в розрізі моделей агреговані для всіх торгових пар, таймфреймів та сигналів для довгих позицій (зелений колір) та коротких позицій (червоний колір)

Також можна побачити більш вузький розподіл Recall для Rocket класифікатора. Також медіанні значення розподілів Precision для коротких позицій нижчі за медіанні значення довгих позицій для всіх моделей. Однак медіанні значення AP для коротких позицій вищі за довгих. Медіанні значення коротких позицій для Sharpe Ratio суттєво нижчі за довгі позиції, що може вказувати на тенденцію

генерувати менші прибутки з більшими ризиками. Розподіли Recall та Precision для довгих та коротких позицій моделі TimeCNN відрізняються суттєво та є найбільш розрідженими з усіх представлених. Також необхідно зауважити, що TimeCNN – це єдиний алгоритм глибокого навчання з усіх представлених в дослідженні, який, як і більшість подібних алгоритмів, чутливий до вибору гіперпараметрів та потребує більше тренувальних даних. Не стверджуються причини відмінностей в метриках для TimeCNN саме в цьому, однак особливості такого алгоритму необхідно мати в контексті.

На рис. 4.31 зображено метрики в розрізі торгових пар агреговані для всіх моделей, таймфреймів та сигналів. Можна побачити, що найбільш розріджені розподіли мають усі пари для Recall, де медіанні значення довгих позицій вищі за короткі для BTC/USDT, ETH/USDT та BNB/USDT, але для інших торгових пар ситуація протилежна. Також для BTC/USDT медіанні значення Precision для коротких позицій помітно нижчі за довгі у порівнянні з іншими парами. Медіанні значення коротких позицій для Sharpe Ratio суттєво нижчі за довгих позицій для всіх пар, що збігається з аналогічним спостереженням в розрізі моделей на рис. 4.31 та на рис. 4.32 (метрики в розрізі часових інтервалів).

На рис. 4.33 зображено метрики в розрізі подій (показників) агреговані для всіх моделей, пар та часових інтервалів. Можна побачити, що для всіх показників простежується тенденція вищих медіанних значень коротких позицій, аніж довгих, для AP, та нижчих для Precision. Також медіанні значення коротких позицій для Sharpe Ratio нижчі за довгих.




Рис. 4.31 – Метрики в розрізі торгових пар агреговані для всіх моделей, таймфреймів та подій для довгих позицій (зелений колір) та коротких позицій (червоний колір)




Рис. 4.32 – Метрики в розрізі часових інтервалів агреговані для всіх моделей, пар та подій для довгих позицій (зелений колір) та коротких позицій (червоний колір)




Рис. 4.33 – Метрики в розрізі подій (показників) агреговані для всіх моделей, пар та часових інтервалів для довгих позицій (зелений колір) та коротких позицій (червоний колір)

Агреговані значення, зображені на рисунках вище, висвітлюють загальні тенденції точності моделей у різних умовах та групах. Для розуміння точності моделей у відсіюванні сигналів, згідно з визначеним багатокритеріальним підходом до прийняття рішень (3.24), зображено в наступних таблицях. В таблиці 4.22 можна побачити співвідношення кількості випадків, коли не Dummy класифікатори



перевершували за складеним балом Dummy класифікатор, в розрізі торгових пар та часових інтервалів, а в таблиці 4.23 в розрізі подій та часових інтервалів. Чим більше співвідношення тим більше випадків, коли інші моделі виявилися більш точними у порівнянні з Dummy класифікатором. Можна побачити, що в усіх агрегаціях співвідношення більше 0.5, що вказує на загальну тенденцію до більшої точності натренованих класифікаторів у порівнянні з Dummy моделлю. Найбільш точні натреновані моделі для пари DOGE/USDT, де для всіх інтервалів співвідношення вище 0.85, а найменш для BNB/USDT годинного інтервалу зі значенням в 0.625.

Таблиця 4.22

Співвідношення кількості випадків, де натреновані класифікатори більш точні за Dummy модель, в розрізі торгових пар та часових інтервалів

Пара	Інтервал	Співвідношення
1	2	3
BTC/USDT	2 години	0.75
BTC/USDT	1 година	0.85
BTC/USDT	30 хвилин	0.775
ETH/USDT	2 години	0.675
ETH/USDT	1 година	0.8
ETH/USDT	30 хвилин	0.75
XRP/USDT	2 години	0.825
XRP/USDT	1 година	0.9
XRP/USDT	30 хвилин	0.775
BNB/USDT	2 години	0.775
BNB/USDT	1 година	0.625

Продовження таблиці 4.22

1	2	3
BNB/USDT	30 хвилин	0.825
DOGE/USDT	2 години	0.85
DOGE/USDT	1 година	0.875
DOGE/USDT	30 хвилин	0.875

У розрізі показників найвищі значення у MAS Sell 1 годинний інтервал з 0.925, а найнижчі у Механістичної ковзної 1 година інтервал з 0.65. Також MFI 1 годинний та 30 хвилинний інтервали мають одні з найвищих значень: 0.9 та 0.875 відповідно.

Таблиця 4.23

Співвідношення кількості випадків, де натреновані класифікатори більш точні за Dummy модель, в розрізі показників та часових інтервалів

Індикатор	Інтервал	Співвідношення
1	2	3
Механістична ковзна	2 години	0.825
Механістична ковзна	1 година	0.65
Механістична ковзна	30 хвилин	0.775
MAS Buy	2 години	0.775
MAS Buy	1 година	0.75
MAS Buy	30 хвилин	0.775
MAS Sell	2 години	0.825
MAS Sell	1 година	0.925

1	2	3
MAS Sell	30 хвилин	0.775
MFI	2 години	0.7
MFI	1 година	0.9
MFI	30 хвилин	0.875
VWMA	2 години	0.75
VWMA	1 година	0.825
VWMA	30 хвилин	0.8

В таблиці 4.24 зображено метрики моделей та загальний бал типової комбінації параметрів. Можна побачити, що MCDA бал (Score), за яким відсортована таблиця, відображає ранг моделей з урахуванням ваг кожної метрики.

Таблиця 4.24

## Ранжування моделей в межах однієї комбінації параметрів

Пара	Інтер-вал	Показ-ник	Вікно	Модель	Roc Auc	Precision	Recall	Sharpe Ratio	Score
1	2	3	4	5	6	7	8	9	10
BTC/USDT	1 година	Мех. ковзна	128	Catch22	0.63	0.65	0.69	2.0	0.88
BTC/USDT	1 година	Мех. ковзна	128	Stacking	0.58	0.66	0.62	1.9	0.84
BTC/USDT	1 година	Мех. ковзна	128	Summary	0.55	0.64	0.48	1.28	0.76
BTC/USDT	1 година	Мех. ковзна	128	Rocket	0.52	0.59	0.59	1.46	0.71

1	2	3	4	5	6	7	8	9	10
BTC/ USDT	1 година	Мех. ковзна	128	Dummy	0.5	0.57	1.0	1.54	0.71
BTC/ USDT	1 година	Мех. ковзна	128	TimeCNN	0.45	0.56	0.85	1.18	0.63

Враховуючи переважно зростаючий тренд цін на обрані топ 5 криптовалют за капіталізацією упродовж періоду 2019 – 2025 років, короткі позиції були менш частими та загалом збитковими. Це відображає ширші ринкові умови, за яких проводилося дослідження. Таким чином, метод продемонстрував більш стабільну прибутковість довгих позицій в періоди з висхідного тренду, аніж за короткими.

#### 4.7 Оцінювання архітектурної стійкості та ізоляції модулів інтелектуальної системи

Для кількісного підтвердження ізоляції ресурсоемних процесів та гнучкості інтеграції показників будемо використовувати архітектурні метрики Р. Мартіна – метрики нестабільності, абстрактності та дистанції до головної послідовності [155]. Аналіз зчеплення виконується на основі показників  $C_a$  – кількість зовнішніх модулів, що залежать від даного, та  $C_e$  – кількість модулів, від яких залежить даний модуль. Метрика нестабільності  $I$  визначається виразом (4.5):

$$I = \frac{C_e}{C_a + C_e}. \quad (4.5)$$

При  $I \rightarrow 0$  маємо стабільний модуль, який є ядром системи, при  $I \rightarrow 1$  спостерігається нестабільний, легко змінюваний модуль.

Метрика абстрактності  $A$  визначається виразом (4.6):

$$A = \frac{N_a}{N_c}, \quad (4.6)$$

де  $N_c$  – загальна кількість класів у конкретному програмному модулі;  $N_a$  – загальна кількість абстрактних класів/інтерфейсів у конкретному програмному модулі.

Метрика показує рівень гнучкості модуля до розширення без необхідності зміни його внутрішньої структури. Значення  $A$  близьке до 0 свідчить про те, що майже всі класи конкретні, модуль сильно прив'язаний до реалізації і його складно розширювати без зміни коду. Значення  $A$  близьке до 1 означає, що майже все визначається через інтерфейси/абстракції, реалізація винесена назовні і легко підміняти компоненти модуля.

Метрика дистанції до головної послідовності  $D$  показує, наскільки модуль збалансований з точки зору його абстрактності та стабільності і обчислюється за виразом (4.7):

$$D = |A + I - 1|. \quad (4.7)$$

Значення  $D$  близькі до 0 визначають добре збалансований модуль, при  $D > 0.3$  вже спостерігається архітектурний дисбаланс.

Згідно з архітектурною схемою (рис. 3.10) та діаграмою класів (рис. 3.11), виділено 4 основні модулі:

- 1) механістичні показники (Indicators): базовий клас + GMI + 5 реалізацій MAS;
  - 2) контур навчання (Training): планівник + 5 ML-алгоритмів + Dummy-класифікатор;
  - 3) контур інференсу (Inference): виконавець у реальному часі + обробник сигналів;
  - 4) менеджер даних (DataManager): API-конектор + логіка збереження у Parquet.
- Результати обчислень наведено в таблиці 4.25.

Таблиця 4.25

Результати обчислення метрик для визначення рівня ізоляції ресурсоемних процесів та гнучкості інтеграції показників

Модуль	$N_a$	$N_c$	$C_a$	$C_e$	$I$	$A$	$D$
Механістичні показники	1	7	3	0	<b>0.00</b>	0.14	0.86
Контур навчання	1	7	1	3	<b>0.75</b>	0.14	0.11
Контур інференсу	0	3	2	3	<b>0.60</b>	0.00	0.40
Менеджер даних	1	4	2	2	<b>0.50</b>	0.25	0.25

Відповідно до результатів, отриманих в таблиці 4.25 модуль «Механістичні показники» є абсолютно стабільним ( $I = 0.00$ ). Він має нульове еферентне зчеплення ( $C_e = 0$ ), тобто не залежить від жодних інших модулів системи, але від нього залежать три інші модулі ( $C_a = 3$ ). Це математично доводить, що розроблені методи є фундаментальним ядром системи і зміни в логіці навчання або інференсу ніяк не впливають на коректність обчислення механістичних показників. Модулі «Контур навчання» та «Контур інференсу» є відносно нестабільними, що є природним для рівнів, які використовують інші компоненти (показники та дані). Важливо, що показник нестабільності інференсу (0.60) нижчий за показник нестабільності навчання (0.75). Це підтверджує гіпотезу про ізоляцію ресурсомістких процесів: контур реального часу менш вразливий до архітектурних флуктуацій, ніж контур періодичного перенавчання моделей. Найвищий показник абстрактності серед активних модулів має модуль «Менеджер даних» ( $A = 0.25$ ). Це свідчить про використання абстрактного шару (інтерфейсів API-конекторів), що дозволяє легко додавати підтримку нових криптовалютних бірж без зміни коду системи збереження (Parquet). Низька абстрактність модулів «Механістичні показники» та «Навчання» ( $A = 0.14$ ) пояснюється високою питомою вагою конкретних реалізацій алгоритмів (5 модифікацій MAS, 5 алгоритмів ML). Для спеціалізованої інтелектуальної системи це є нормою, оскільки основна цінність полягає в точності конкретних математичних моделей. Дистанції до головної послідовності модулів «Контур навчання» ( $D = 0.11$ ) та «Менеджер даних» ( $D = 0.25$ ) близькі до нуля, що означає, що ці модулі знаходяться в балансі між своєю стійкістю та рівнем абстракції. Вони не є ні занадто стабільними й не абстрактними, від яких не залежать інші модулі. Модуль «Механістичні показники» має значення дистанції  $D = 0.86$ . Таке високе відхилення зумовлене тим, що модуль є максимально конкретним ( $A = 0.14$ ) і максимально стабільним ( $I = 0.00$ ). У межах розробленої архітектури це обґрунтовано – модуль є технологічним фундаментом, який не повинен бути абстрактним, оскільки він реалізує фіксовані закони еконофізики.

## Висновки до розділу 4

У цьому розділі висвітлено наступні результати дослідження:

1) виявлено сильні сторони та обмеження чотирьох методів аналізу торгових обсягів: OBV, MFI, Індикатор накопичення/розподілу та Механістичний імпульс;

2) продемонстровано адаптацію механістичного підходу до специфіки криптовалютного ринку. Результати тестування на прикладі Bitcoin за 2021 рік показали, що проста ковзна середня не завжди встигає за швидкими ринковими змінами, що обмежує її точність. Натомість використання експоненціальних ковзних середніх (EMA), які швидше реагують на нову інформацію, дало покращені результати як за кількістю прибуткових угод, так і за середнім прибутком з 5.6% до 8.8% на одну угоду;

3) представлено аналіз механістичної простої ковзної середньої (MSMA) та традиційної простої ковзної середньої (SMA). Порівняльний аналіз прибутковості MSMA та SMA показує, що MSMA, як правило, забезпечує більш стабільну прибутковість, з меншою волатильністю та вищим коефіцієнтом виграшу (52.2%) порівняно з SMA (43.1%). У той час як SMA демонструє потенціал для вищої прибутковості в певних випадках (максимальна прибутковість 282.2% проти 151.5% у MSMA). Аналіз прибутковості відносно ринкових тенденцій Bitcoin показав, що як SMA, так і MSMA залежать від напрямків тренду, але по-різному. SMA демонстрував тенденцію до більш екстремальної прибутковості під час сильних висхідних трендів, що узгоджується з його вищим профілем волатильності. MSMA, навпаки, продемонстрував стабільніші прибутки як під час висхідних, так і під час низхідних трендів, хоча його прибутковість загалом була нижчою. Причинно-наслідковий аналіз підтвердив негативний ефект використання MSMA порівняно з SMA, при цьому оціночний ATE вказував на те, що MSMA має в середньому на 3.5% – 6.0% нижчу прибутковість, аніж SMA;

4) продемонстровано результати тестувань удосконаленого методу механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці. Найбільш точним показником у тестуванні виявився імпульс обсягів покупок (GMI

Volume Buy), який демонструє найвищу прибутковість і точність на всіх часових інтервалах. Імпульс різниці обсягів (GMI Volume Delta) показав найнижчі результати щодо прибутковості та коефіцієнта виграшу. На менших інтервалах (30-хвилинний) точність і прибутковість зменшується, а ризики збільшуються, тоді як на денному та 4-годинному інтервалах результати стабільніші, а порівняння зі стратегією “купи та тримай” (Buy and Hold);

5) протестовано показник поглинання імпульсу (MAS) – показник, мета якого ідентифікувати потенційний ціновий імпульс шляхом виявлення ситуацій, коли великі обсяги торгів поглинаються без значних цінових коливань. У дослідженні запропоновано п'ять реалізацій MAS на різних таймфреймах та торгових стратегіях. Дослідження продемонструвало, що показник поглинання імпульсу може точно виявляти ситуації, коли великі обсяги торгів передують значним ціновим коливанням, причому більшість варіантів MAS генерують прибуткові сигнали. Покращена стратегія послідовно перевершувала Базову стратегію на всіх таймфреймах та варіантах MAS. Менші таймфрейми (особливо 30-хвилинний таймфрейм) зазвичай приносили вищий загальний прибуток, але нижчий середній прибуток на угоду порівняно з більшими таймфреймами. Ця закономірність вказує на компроміс між частотою та величиною окремих цінових коливань. Довгі позиції перевершували короткі позиції майже на всіх варіантах та таймфреймах MAS. Це узгоджується із загальним висхідним трендом біткоїна упродовж періоду тестування;

6) проаналізовано точність удосконаленого методу прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу. Усі протестовані моделі машинного навчання (Summary, Catch22, Rocket, Stacking), окрім TimeCNN продемонстрували кращу точність у порівнянні з Dummy-класифікатором у більшості розрізів – за торговими парами, часовими інтервалами та показниками. Найбільш стабільні результати продемонстрував Rocket-класифікатор, особливо у контексті Recall, з помірною варіативністю та високою медіаною. У свою чергу, TimeCNN виявився найменш стабільним, що ймовірно пов'язано з чутливістю до гіперпараметрів та потребою в більшому обсязі даних. Метрики Sharpe Ratio для



коротких позицій були помітно нижчими в порівнянні з довгими позиціями. Це вказує на загалом вищі ризики та меншу прибутковість коротких позицій у контексті зростаючого ринкового тренду криптовалют у 2019 - 2025 роках. Варіація вікон (16, 32, 64, 128) показала, що оптимальні комбінації параметрів можуть суттєво впливати на точність моделей. Багатокритеріальний підхід до оцінювання моделей (MCDA) дозволив не лише ранжувати моделі за узагальненим балом, але й виявити ті конфігурації, які мають найбільший потенціал прибутковості за прийнятного рівня ризику. Це підкреслює перевагу застосування комплексного підходу для задач відсіювання сигналів;

7) за результатами розрахунку архітектурних метрик Р. Мартіна встановлено оптимальний рівень стабільності контуру інференсу ( $I = 0.60$ ), що за умови повної відсутності його залежності від модуля навчання математично підтверджує ізоляцію критичних процесів. Мінімальна дистанція до головної послідовності для основних компонентів ( $D \in [0.11; 0.40]$ ) доводить структурну збалансованість системи, забезпечуючи безперебійну обробку потокових даних незалежно від циклів періодичного перенавчання моделей.

## ВИСНОВКИ

Метод аналізу та прогнозування динаміки ринку криптовалют за допомогою механістичного підходу та машинного навчання є результатом розв'язання науково-прикладної проблеми, що полягає у підвищенні достовірності аналізу та прогнозування фінансових часових рядів шляхом моделювання прихованих механізмів формування ціни через взаємодію ціни та обсягу, що дозволяє точніше оцінювати баланс попиту та пропозиції, а також знижувати вплив шумових торгових сигналів в умовах невизначеності криптовалютного ринку.

У процесі виконання дисертаційної роботи отримані наступні результати:

1. Проведено аналіз методів технічного аналізу, алгоритмічної торгівлі та машинного навчання, досліджено особливості криптовалютного ринку як нестационарної системи, обґрунтовано роль механістичного підходу в задачах інтелектуальної обробки фінансових даних, що дозволило сформулювати вимоги до створення нових теоретичних і прикладних засобів.

2. Удосконалено метод механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці, що дозволило формалізовано оцінювати взаємодію попиту та пропозиції в умовах високої волатильності та нестационарності ринку. Продемонстровано, що запропоновані модифікації дозволяють ідентифікувати дисбаланси між ринковими покупками та продажами, які є ключовими індикаторами зміни цінових тенденцій. Встановлено, що механістичний показник ринкових покупок більш точний за механістичний показник сумарних обсягів на денному (50.6% проти 50.1%), 4-годинному (43.6% проти 43.4%) та 30 хвилинному (38.2% проти 37.9%) інтервалах.

3. Вперше розроблено показник поглинання імпульсу (Momentum Absorption Score, MAS), який ґрунтується на статистичному виявленні зон низької волатильності при аномально високих торгових обсягах за допомогою z-оцінок та процентильного аналізу і є складовою удосконаленого методу механістичного аналізу динаміки криптовалютних активів, що дозволило ідентифікувати приховані фази накопичення

та розподілу активів, які передують значним ціновим рухам. Продемонстровано, що показник поглинання імпульсу є своєрідним протиставленням механістичній ковзній, оскільки пікові значення останньої переважно припадають на високу волатильність, на відміну від MAS. Встановлено, що показник поглинання імпульсу сумарних обсягів більш точний за механістичну ковзну та VWMA на денному (50% проти 38.1% та 42.31% відповідно), 4-годинному (36.84% проти 35.98% та 34.43% відповідно) та 30-хвилинному (53.69% проти 29.31% та 34.98% відповідно).

4. Удосконалено метод прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу (механістичної ковзної та показника MAS) із застосуванням ансамблевого машинного навчання та класифікації прибутковості подій за методом потрійних бар'єрів, що дозволило підвищити точність ідентифікації інформативних сигналів та мінімізувати вплив ринкового шуму. Встановлено, що точність класифікаторів у відсіюванні сигналів, згідно з визначеним багатокритеріальним підходом до прийняття рішень, в розрізі торгових пар та подій мають співвідношення більше за 0.5 у порівнянні з підходом без інтелектуальної фільтрації (Dummy). Найбільш точними моделі виявились для пари DOGE/USDT, де для всіх інтервалів співвідношення вище 0.85, а найменш для BNB/USDT годинного інтервалу зі значенням в 0.625, що все одно вище, за 0.5 у Dummy моделі.

5. Дістали подальшого розвитку архітектурні рішення реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи за рахунок впровадження модульної монолітної структури з розділеними контурами навчання та інференсу, що дозволило забезпечити ізоляцію ресурсоемних процесів та спростити інтеграцію механістичних показників. За результатами розрахунку архітектурних метрик Р. Мартіна встановлено оптимальний рівень стабільності контуру інференсу ( $I = 0.60$ ), що за умови повної відсутності його залежності від модуля навчання математично підтверджує ізоляцію критичних процесів. Мінімальна дистанція до головної послідовності для основних компонентів ( $D \in [0.11; 0.40]$ ) доводить структурну збалансованість системи, забезпечуючи

безперебійну обробку поточкових даних незалежно від циклів періодичного перенавчання моделей.

6. Проведено експериментальне дослідження розроблених методів, моделей та програмних засобів на історичних даних для оцінки їхньої точності та обчислювальної продуктивності в реальних ринкових умовах. Продемонстровано, що проведені дослідження підтвердили достовірність теоретичних положень. Встановлено, що використання технологій ЛТ-компіляції та паралелізації обчислень у програмній реалізації розроблених моделей дозволило досягти суттєвого підвищення обчислювальної продуктивності, що виражається у скороченні часу розрахунку складних показників з 2,0 до 0,6 секунди.

7. Наукові положення, теоретичні та експериментальні результати, отримані в дисертаційній роботі, впроваджені у практичну діяльність ФОП Новіцька А. В. (акт від 01.05.2026 р.) та дозволили підвищити обґрунтованість бізнес-рішень у комунікації з інвесторами, партнерами по біржі та розробки токеноміки для майбутніх клієнтів, зменшити відсоток хибно позитивних оцінок цінової динаміки токеноу компанії у наступні 3, 6 та 12 місяців на 11% та скоротити час на аналіз ринкових даних на 40% завдяки впровадженню програмно-технологічних засобів реалізації інтелектуальних систем аналізу даних.

Перспективами подальшого розвитку дослідження є розширення експериментальної бази через апробацію методу на традиційних фондових ринках та активах із низькою капіталізацією, а також посилення прогностичної здатності моделей шляхом залучення альтернативних джерел даних, зокрема on-chain показників руху активів на гаманцях та результатів аналізу настроїв у медіапросторі. З інженерної точки зору розвиток може включати еволюцію архітектури шляхом переходу до мікросервісної організації для забезпечення ще вищого рівня ізоляції критичних процесів та впровадження розподілених обчислень на базі GPU для скорочення часу перенавчання ансамблевих моделей.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Диха М., Фролов С., Грабар В. Криптовалюта: особливості та перспективи розвитку. Світ фінансів. 2023. № 1(74). С. 93-103. DOI: 10.35774/SF2023.01.093 URL: <http://sf.wunu.edu.ua/index.php/sf/article/view/1589>.
2. Zhebka, Viktoriia & Zhebka, Serhii & Bazhan, Tetiana & Skladannyi, Pavlo & Sokolov, Volodymyr. Methodology for Choosing a Consensus Algorithm for Blockchain Technology. Digital Economy Concepts and Technologies Workshop (2024), 2024, 3665, pp. 106-113.
3. Єлисеєва О. Є., Волошина О. В., Дідур С. В. Біткойн як елемент сучасної фінансової системи. Економіка і суспільство. 2018, №18, С. 733-741. DOI: <https://doi.org/10.32782/2524-0072/2018-18-103>.
4. Malinov, V., Zhebka, V., Kokhan, I., Storchak, K., Dovzhenko, T. (2024). Cryptocurrency as a Tool for Attracting Investment and Ensuring the Strategic Development of the Bioenergy Potential of Processing Enterprises in Ukraine. In: Semenov, A., Yepifanova, I., Kajanová, J. (eds) Data-Centric Business and Applications. Lecture Notes on Data Engineering and Communications Technologies, vol 195. Springer, Cham. [https://doi.org/10.1007/978-3-031-54012-7\\_17](https://doi.org/10.1007/978-3-031-54012-7_17).
5. Устименко, В., Поліщук, Н. (2024) «Перспективи застосування криптовалют в електроенергетиці України: зарубіжний досвід і вітчизняні здобутки», Economics and Law, 53(2), с. 64–69. doi: 10.15407/econlaw.2019.02.064.
6. Liang J. & li., L. & Chen W., Zeng D. D. (2019). Towards an Understanding of Cryptocurrency: A Comparative Analysis of Cryptocurrency, Foreign Exchange, and Stock. 10.1109/ISI.2019.8823373.
7. Nilcan Mert, Mustafa Caner Timur. Bitcoin and money supply relationship: An analysis of selected country economies[J]. Quantitative Finance and Economics, 2023, 7(2): 229-248. doi: 10.3934/QFE.2023012.

8. Bianchi, D., Guidolin, M. and Pedio, M. (2022) 'The dynamics of returns predictability in cryptocurrency markets', *The European Journal of Finance*, 29(6), pp. 583–611. doi: 10.1080/1351847X.2022.2084343.
9. Freire, Rosane & Fernandes, Cristiano & Lorenzoni, Giuliano & Pizzinga, Adrian & Atherino, Rodrigo. (2007). On the Statistical Validation of Technical Analysis. *Revista Brasileira de Finanças*. 5.
10. Edwards, R. D., Magee, J., & Bassetti, W.C. *Technical analysis of stock trends*. CRC press, 2018. 686 p.
11. Hyndman, R. *International Encyclopedia of Statistical Science*. Springer, 2011. 1673 p.
12. Mazumder, S., Neogy, S., & Das, S. Simple Moving Average (SMA) Crossover Strategy with Buy Sell Indicator. *Advancement in Management and Technology (AMT)*, 2023, vol. 3, iss. 4, pp. 26-40. DOI: 10.46977/apjmt.2023.v03i04.004.
13. Ejder, U., & Özel, S. A. A novel distance-based moving average model for improvement in the predictive accuracy of financial time series. *Borsa Istanbul Review*, 2024, vol. 24, iss. 2, pp. 376-397. DOI: 10.1016/j.bir.2024.01.011.
14. Katz, H., Brusch, K. T., & Weiss, R. E. A Bayesian Dirichlet auto-regressive moving average model for forecasting lead times. *International Journal of Forecasting*, 2024, vol. 40, iss. 4, pp. 1556-1567. DOI: 10.1016/j.ijforecast.2024.01.004.
15. Ellis, C. A., & Parbery, S. A. (2005). Is smarter better? A comparison of adaptive, and simple moving average trading strategies. *Research in International Business and Finance*, 19(September (3)), 399–411.
16. Fong, W. M., & Yong, L. H. (2005). Chasing trends: Recursive moving average trading rules and internet stocks. *Journal of Empirical Finance*, 12(January (1)), 43–76
17. Gong, L., Gong, W., Luo, J., & Yang, R. (2024). Trend-Enhanced Improved Bollinger Bands Trend-Following High-Frequency Trading Strategy for Futures Market. *Highlights in Business, Economics and Management*, 24, 1702-1709. <https://doi.org/10.54097/btgview93>.

18. Ikhlās Gurrib (2018). Performance of the Average Directional Index as a market timing tool for the most actively traded USD based currency pairs. *Banks and Bank Systems*, 13(3), 58-70. doi:10.21511/bbs.13(3).2018.06
19. Joshi, D. L. (2022) "Use of Moving Average Convergence Divergence for Predicting Price Movements", *International Research Journal of MMC*, 3(4), pp. 21–25. doi: 10.3126/irjmmc.v3i4.48859.
20. Zatwarnicki, Marek, Krzysztof Zatwarnicki, and Piotr Stolarski. 2023. "Effectiveness of the Relative Strength Index Signals in Timing the Cryptocurrency Market" *Sensors* 23, no. 3: 1664. <https://doi.org/10.3390/s23031664>.
21. Resta M., Pagnottoni P., De Giuli M. Technical Analysis on the Bitcoin Market: Trading Opportunities or Investors' Pitfall?. *Risks*. 2020. 8. 44. 10.3390/risks8020044.
22. L. Xuan, C. Guozhong and L. Fulong, "Stock data analysis based on Hilbert-Huang transform," 2015 IEEE International Conference on Grey Systems and Intelligent Services (GSIS), Leicester, UK, 2015, pp. 618-621, doi: 10.1109/GSIS.2015.7301816.
23. Costa, T. R. C. C. d., Nazário, R. T., Bergo, G. S. Z., Sobreiro, V. A., & Kimura, H. (2015). Trading system based on the use of technical analysis: A computational experiment. *Journal of Behavioral and Experimental Finance*, 6(June (1)), 42–55.
24. Dawson, E. R., & Steeley, J. M. (2003). On the existence of visual technical patterns in the UK stock market. *Journal of Business Finance & Accounting*, 30(January (1–2)), 263–293.
25. Friesen, G. C., Weller, P. A., & Dunham, L. M. (2009). Price trends and patterns in technical analysis: A theoretical and empirical examination. *Journal of Banking & Finance*, 33(June (6)), 1089–1100.
26. Park, C.-H., & Irwin, S. H. (2007). What do we know about the profitability of technical analysis? *Journal of Economic Surveys*, 21(September (4)), 786–826.
27. Rui, Oliver & Chen, Gong-meng & Firth, Michael. (2001). The Dynamic Relation Between Stock Returns, Trading Volume, and Volatility. *The Financial Review*. 36. 153-73. 10.1111/j.1540-6288.2001.tb00024.x.

28. Blume, L., Easley, D., & O'Hara, M. (1994). Market Statistics and Technical Analysis: The Role of Volume. *The Journal of Finance*, 49(1), 153–181.  
<https://doi.org/10.2307/2329139>
29. Abbondante, P. Trading Volume and Stock Indices: A Test of Technical Analysis. *American Journal of Economics and Business Administration*, 2010, vol. 2, no. 3, pp. 287-292. DOI: 10.3844/ajebasp.2010.287.292.
30. Bouri, Elie & Lau, Chi Keung Marco & Lucey, Brian & Roubaud, David, 2019. "Trading volume and the predictability of return and volatility in the cryptocurrency market," *Finance Research Letters*, Elsevier, vol. 29(C), pages 340-346.
31. Aalborg, Halvor & Molnár, Peter & Vries, Jon. (2018). What can explain the price, volatility and trading volume of Bitcoin?. *Finance Research Letters*. 29. 10.1016/j.frl.2018.08.010.
32. Mitchell, D., Białkowski, J., & Tompaidis, S. Volume-weighted average price tracking: A theoretical and empirical study. *IISE Transactions*, 2019, vol. 52, iss. 8, pp. 864-889. DOI: 10.1080/24725854.2019.1688896.
33. Tsang, William & Chong, Terence. (2009). Profitability of the On-Balance Volume Indicator. *Economics Bulletin*. 29. 2424-2431.
34. Marek, Patrice & Marková, Věra. (2020). Optimization and Testing of Money Flow Index.
35. Shanmugam, "A Study on Accumulation and Distribution Indicator for Trading in Indian Stock Market," vol. 48, pp. 167-172, 2024.
36. Zarattini, Carlo and Aziz, Andrew, Volume Weighted Average Price (VWAP) The Holy Grail for Day Trading Systems (November 13, 2023). Available at SSRN: <https://ssrn.com/abstract=4631351> or <http://dx.doi.org/10.2139/ssrn.4631351>.
37. Klinger, S. Identifying Trends with Volume Analysis. *Technical Analysis of Stocks & Commodities Magazine*, 1997, Vol. 15, Issue 12.
38. Alexander, Carol and Heck, Daniel and Kaeck, Andreas and Riordan, Ryan, Order Flow Impact and Price Formation in Centralized Crypto Exchanges (June 15, 2024). Available at SSRN: <https://ssrn.com/abstract=4867599> or <http://dx.doi.org/10.2139/ssrn.4867599>



39. Abergel, Frédéric, Marouane Anane, Anirban Chakraborti, Aymen Jedidi, and Ioane Muni Toke. *Limit Order Books. of Physics of Society: Econophysics and Sociophysics*. Cambridge: Cambridge University Press, 2016.
40. Foucault, Thierry, Ohad Kadan, and Eugene Kandel. "Limit Order Book as a Market for Liquidity." *The Review of Financial Studies* 18, no. 4 (2005): 1171–1217. <http://www.jstor.org/stable/3598019>.
41. Gould, Martin David and Porter, Mason Alexander and Williams, Stacy and McDonald, Mark and Fenn, Daniel and Howison, Sam, *Limit Order Books* (April 27, 2012). Available at SSRN: <https://ssrn.com/abstract=1970185> or <http://dx.doi.org/10.2139/ssrn.1970185>
42. Capponi, Agostino, and Charles-Albert Lehalle, eds. "Order Flow and Price Formation." Chapter. In *Machine Learning and Data Sciences for Financial Markets: A Guide to Contemporary Practices*, 107–29. Cambridge: Cambridge University Press, 2023.
43. Charoenwong, Charlie and Visaltanachoti, Nuttawat and Ding, David K., *Analysis of Limit Order Book and Order Flow* (July 2003). Available at SSRN: <https://ssrn.com/abstract=488422> or <http://dx.doi.org/10.2139/ssrn.488422>
44. Bae, Kee-Hong & Jang, Hasung & Park, Kyung. (2003). Traders' choice between limit and market orders: Evidence from NYSE stocks. *Journal of Financial Markets*. 6. 517-538. 10.1016/S1386-4181(02)00047-2.
45. Hautsch, Nikolaus and Huang, Ruihong, *The Market Impact of a Limit Order* (June 21, 2011). *Journal of Economic Dynamics and Control*, Forthcoming, Available at SSRN: <https://ssrn.com/abstract=1677343> or <http://dx.doi.org/10.2139/ssrn.167734>.
46. Waelbroeck, Henri and Gomes, Carla, *Is Market Impact a Measure of the Information Value of Trades? Market Response to Liquidity vs. Informed Trades* (July 9, 2013). Available at SSRN: <https://ssrn.com/abstract=2291720> or <http://dx.doi.org/10.2139/ssrn.2291720>.
47. Chaboud, Alain and Hjalmarsson, Erik and Zikes, Filip, *The Evolution of Price Discovery in an Electronic Market* (June, 2020). FEDS Working Paper No. 2020-51,

Available at SSRN: <https://ssrn.com/abstract=3635495> or <http://dx.doi.org/10.17016/FEDS.2020.051>.

48. Goettler, Ronald L. and Parlour, Christine A. and Rajan, Uday, Informed Traders and Limit Order Markets (January 12, 2008). Available at SSRN: <https://ssrn.com/abstract=933358> or <http://dx.doi.org/10.2139/ssrn.933358>.
49. Gheorghe Săvoiu, Constantin Andronache. Chapter 7 - The Potential of Econophysics for the Study of Economic Processes. *Econophysics*, 2013, Pages 91-113, <https://doi.org/10.1016/B978-0-12-404626-9.00007-4>.
50. Bouchaud, J., 2002. An introduction to statistical finance. *Phys. A: Stat. Mech. Appl.* 313 (12), 238251.
51. McCauley, J.L., 2004a. *Dynamics of Markets: Econophysics and Finance*. Cambridge University Press, Cambridge.
52. Latora, V, Marchiori, M., 2003. *The Architecture of Complex Systems*. Santa Fe Institute for Studies of Complexity, Oxford University Press, Oxford.
53. Latora, V., Marchiori, M., 2004. How the science of complex networks can help developing strategies against terrorism. *Chaos Solitons Fractals* 20, 6975.
54. Makowski, M.; Piotrowski, E.W.; Frąckiewicz, P.; Szopa, M. Transactional Interpretation for the Principle of Minimum Fisher Information. *Entropy* 2021, 23, 1464.
55. Biondo, Alessio Emanuele & Pluchino, Alessandro & Rapisarda, Andrea. (2015). Modeling Financial Markets by Self-Organized Criticality. *Physical Review E*. 92. 042814. [10.1103/PhysRevE.92.042814](https://doi.org/10.1103/PhysRevE.92.042814).
56. Qingxue Wang, Bin Teng, Qi Hao, Yufeng Shi. High-frequency Statistical Arbitrage Strategy Based on Stationarized Order Flow Imbalance. *Procedia Computer Science*, vol. 187, 2021, pp. 518-523.
57. Zhou, WX., Sornette, D. Self-organizing Ising model of financial markets. *Eur. Phys. J. B* 55, 175–181 (2007). <https://doi.org/10.1140/epjb/e2006-00391-6>.
58. Kelly, Bryan T. and Xiu, Dacheng, *Financial Machine Learning* (July 1, 2023), <http://dx.doi.org/10.2139/ssrn.4501707>.

59. Ausloos, Marcel & Ivanova, Katrin. (2002). Mechanistic approach to generalized technical analysis of share prices and stock market indices. *European Physical Journal B*. 27. 10.1140/epjb/e20020144.
60. Sarker, I.H. Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN COMPUT. SCI.* 2, 160 (2021). <https://doi.org/10.1007/s42979-021-00592-x>.
61. Dokuz, Ahmet & Celik, Mete & Ecemiş, Alper. (2020). Anomaly Detection in Bitcoin Prices using DBSCAN Algorithm. 436-443. 10.31590/ejosat.araconf57.
62. Thibaut Théate, Damien Ernst, An application of deep reinforcement learning to algorithmic trading, *Expert Systems with Applications*, Volume 173, 2021. <https://doi.org/10.1016/j.eswa.2021.114632>.
63. Maulud, Dastan & Abdulazeez, Adnan. (2020). A Review on Linear Regression Comprehensive in Machine Learning. *Journal of Applied Science and Technology Trends*. 1. 140-147. 10.38094/jastt1457.
64. Бовчалюк С. Я., Гайдай Я. А. АНАЛІЗ МЕТОДУ ОПОРНИХ ВЕКТОРІВ У ПОРІВНЯННІ З ТРАДИЦІЙНИМИ МЕТОДАМИ ПЕРЕДБАЧЕННЯ РИНКОВИХ РУХІВ. *Системи управління, навігації та зв'язку*. 2024. Збірник наукових праць. №3. С. 89-92. DOI: 10.26906/SUNZ.2024.3.089.
65. Guo, Gongde & Wang, Hui & Bell, David & Bi, Yaxin & Greer, Kieran. (2003). KNN Model-Based Approach in Classification. *Lect Notes Comput Sci*. 2888. 986-996. 10.1007/978-3-540-39964-3\_62.
66. Rokach, Lior & Maimon, Oded. (2005). Decision Trees. 10.1007/0-387-25465-X\_9.
67. Бажан Т. О. Порівняльний аналіз методів машинного навчання для побудови прогнозів. *Сучасний захист інформації*, 2024, №4 (60). DOI: 10.31673/2409-7292.2024.040013.
68. Friedman J. H. machine. Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*. 2001. Vol. 29, no. 5. P. 1189–1232. URL: <https://doi.org/10.1214/aos/1013203451>.

69. Qamar, Roheen & Zardari, Baqar. (2023). Artificial Neural Networks: An Overview. Mesopotamian Journal of Computer Science. 2023. 130-139. 10.58496/MJCSC/2023/015.
70. Jesper Sören Drams, Chapter One - 70 years of machine learning in geoscience in review, Editor(s): Ben Moseley, Lion Krischer, Advances in Geophysics, Elsevier, Volume 61, 2020, Pages 1-55.
71. Goodfellow, Ian & Pouget-Abadie, Jean & Mirza, Mehdi & Xu, Bing & Warde-Farley, David & Ozair, Sherjil & Courville, Aaron & Bengio, Y.. (2014). Generative Adversarial Networks. Advances in Neural Information Processing Systems. 3. 10.1145/3422622.
72. Vaswani, Ashish, Noam M. Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser and Illia Polosukhin. "Attention is All you Need." Neural Information Processing Systems (2017).
73. Корабльов М. М., Антонов Д. О. ПРОГНОЗУВАННЯ ФІНАНСОВОГО РИНКУ З ВИКОРИСТАННЯМ НЕЙРОМЕРЕЖЕВОГО ТА ІМУННОГО ПІДХОДІВ. Обчислювальна техніка та автоматизація, 2026, №6 (38), с. 32-38. URL: <https://ota-new.donntu.edu.ua/article/view/359123/344872>.
74. Ткаченко, О. М., Грійо Тукало, О. Ф., Дзісь, О. В. і Лаховець, С. М. Метод кластеризації на основі послідовного запуску k-середніх з удосконаленням вибором кандидата на нову позицію вставки. Наукові праці Вінницького національного технічного університету, 2012, №2, с. 1-10. URL: <https://praci.vntu.edu.ua/index.php/praci/article/view/323> (дата звернення: 06.05.2026).
75. Мацуга О. М., Фунтиков М. К. Технологія групування ознак в наборах даних на основі ієрархічної кластеризації. Актуальні проблеми автоматизації та інформаційних технологій, 2024, № 28, 193-204. DOI: <http://dx.doi.org/10.15421/432418>.
76. Patel J, Shah S, Thakkar P, Kotecha K. Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. Expert systems with applications. 2015; 42(1): 259-268.

77. Vui CS, Soon GK, On CK, Alfred R, Anthony P. A review of stock market prediction with Artificial neural network (ANN). In: 2013 IEEE international conference on control system, computing and engineering. IEEE; 2013. p. 477-82.
78. Bing Y, Hao JK, Zhang SC. Stock market prediction using artificial neural networks. In: Advanced Engineering Forum. vol. 6. Trans Tech Publ; 2012. p. 1055-60.
79. Dai W, Wu JY, Lu CJ. Combining nonlinear independent component analysis and neural network for the prediction of Asian stock market indexes. Expert systems with applications. 2012;39(4):4444-52.
80. Selvin S, Vinayakumar R, Gopalakrishnan E, Menon VK, Soman K. Stock price prediction using LSTM, RNN and CNN-sliding window model. In: 2017 international conference on advances in computing, communications and informatics (icacci). IEEE; 2017. p. 1643-7.
81. Chen K, Zhou Y, Dai F. A LSTM-based method for stock returns prediction: A case study of China stock market. In: 2015 IEEE international conference on big data (big data). IEEE; 2015. p. 2823-4.
82. Nelson DM, Pereira AC, De Oliveira RA. Stock market's price movement prediction with LSTM neural networks. In: 2017 International jointconference on neural networks (IJCNN). Ieee; 2017. p. 1419-26
83. Moghar A, Hamiche M. Stock market prediction using LSTM recurrent neural network. Procedia Computer Science. 2020;170:1168-73.
84. Roondiwala M, Patel H, Varma S. Predicting stock prices using LSTM. International Journal of Science and Research (IJSR). 2017;6(4):1754-6.
85. Ticknor JL. A Bayesian regularized artificial neural network for stock market forecasting. Expert systems with applications. 2013;40(14):5501-6.
86. Zhang K, Zhong G, Dong J, Wang S, Wang Y. Stock market prediction based on generative adversarial network. Procedia computer science. 2019;147:400-6.
87. Akita R, Yoshihara A, Matsubara T, Uehara K. Deep learning for stock prediction using numerical and textual information. In: 2016 IEEE/ACIS15th International Conference on Computer and Information Science (ICIS). IEEE; 2016. p. 1-6

88. Li X, Xie H, Wang R, Cai Y, Cao J, Wang F, et al. Empirical analysis: stock market prediction via extreme learning machine. *Neural Computing and Applications*. 2016;27(1):67-78.
89. Ding X, Zhang Y, Liu T, Duan J. Using structured events to predict stock price movement: An empirical investigation. In: *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*; 2014. p. 1415-25.
90. Ren R, Wu DD, Liu T. Forecasting stock market movement direction using sentiment analysis and support vector machine. *IEEE Systems Journal*. 2018;13(1):760-70.
91. Kazem A, Sharifi E, Hussain FK, Saberi M, Hussain OK. Support vector regression with chaos-based firefly algorithm for stock market price forecasting. *Applied soft computing*. 2013;13(2):947-58
92. Alkhatib K, Najadat H, Hmeidi I, Shatnawi MKA. Stock price prediction using k-nearest neighbor (kNN) algorithm. *International Journal of Business, Humanities and Technology*. 2013;3(3):32-44.
93. Chang PC, et al. A novel model by evolving partially connected neural network for stock price trend forecasting. *Expert Systems with Applications*. 2012;39(1):611-20.
94. Sonkavde, Gaurang & Dharrao, Deepak & Bongale, Arunkumar & Deokate, Sarika & Doreswamy, Deepak & Bhat, Subraya. (2023). Forecasting Stock Market Prices Using Machine Learning and Deep Learning Models: A Systematic Review, Performance Analysis and Discussion of Implications. *International Journal of Financial Studies*. 11. 94. 10.3390/ijfs11030094.
95. Yang, C.-Y. et al. (2024) 'Advancing Financial Forecasts: Stock Price Prediction Based on Time Series and Machine Learning Techniques', *Applied Artificial Intelligence*, 38(1). doi: 10.1080/08839514.2024.2429188.
96. D. C. Mallqui, R. A. Fernandes, Predicting the direction, maximum, minimum and closing prices of daily bitcoin exchange rate using machine learning techniques, *Applied Soft Computing* 75 (2019) 596–606.
97. K. Murray, A. Rossi, D. Carraro, A. Visentin, On forecasting cryptocurrency prices: A comparison of machine learning, deep learning, and ensembles, *Forecasting* 5 (1) (2023) 196–209.

98. V. Derbentsev, N. Datsenko, O. Stepanenko, V. Bezkorovainyi, Forecasting cryptocurrency prices time series using machine learning approach, in: SHS Web of Conferences, Vol. 65, EDP Sciences, 2019, p. 02001.
99. S. Roy, S. Nanjiba, A. Chakrabarty, Bitcoin price forecasting using time series analysis, in: 2018 21st International Conference of Computer and Information Technology (ICCIT), IEEE, 2018, pp. 1–5.
100. N. Maleki, A. Nikoubin, M. Rabbani, Y. Zeinali, Bitcoin price prediction based on other cryptocurrencies using machine learning and time series analysis, *Scientia Iranica* 30 (1) (2023) 285–301.
101. Y. Wang, G. Andreeva, B. Martin-Barragan, Machine learning approaches to forecasting cryptocurrency volatility: Considering internal and external determinants, *International Review of Financial Analysis* 90 (2023) 102914.
102. V. D'Amato, S. Levantesi, G. Piscopo, Deep learning in predicting cryptocurrency volatility, *Physica A: Statistical Mechanics and its Applications* 596 (2022) 127158.
103. L. Catania, S. Grassi, F. Ravazzolo, Predicting the volatility of cryptocurrency time-series, *Mathematical and Statistical Methods for Actuarial Sciences and Finance: MAF 2018* (2018) 203–207.
104. T. Guo, A. Bifet, N. Antulov-Fantulin, Bitcoin volatility forecasting with a glimpse into buy and sell orders, in: 2018 IEEE international conference on data mining (ICDM), IEEE, 2018, pp. 989–994.
105. F. Ma, C. Liang, Y. Ma, M. I. M. Wahab, Cryptocurrency volatility forecasting: A markov regime-switching midas approach, *Journal of Forecasting* 39 (8) (2020) 1277–1290.
106. M. A. Ammer, T. H. Aldhyani, Deep learning algorithm to predict cryptocurrency fluctuation prices: Increasing investment awareness, *Electronics* 11 (15) (2022) 2349.
107. B. Ly, D. Timaul, A. Lukanan, J. Lau, E. Steinmetz, Applying deep learning to better predict cryptocurrency trends, in: Midwest Instruction and Computing Symposium, 2018

108. S. Lahmiri, S. Bekiros, Cryptocurrency forecasting with deep learning chaotic neural networks, *Chaos, Solitons & Fractals* 118 (2019) 35–40.
109. P. L. Seabe, C. R. B. Moutsinga, E. Pindza, Forecasting cryptocurrency prices using lstm, gru, and bi-directional lstm: A deep learning approach, *Fractal and Fractional* 7 (2) (2023) 203
110. C.-H. Wu, C.-C. Lu, Y.-F. Ma, R.-S. Lu, A new forecasting framework for bitcoin price with lstm, in: 2018 IEEE international conference on data mining workshops (ICDMW), IEEE, 2018, pp. 168–175.
111. I. E. Livieris, E. Pintelas, S. Stavroyiannis, P. Pintelas, Ensemble deep learning models for forecasting cryptocurrency time-series, *Algorithms* 13 (5) (2020) 121.
112. S. Aanandhi, S. Akhilaa, V. Vardarajan, M. Sathiyarayanan, et al., Cryptocurrency price prediction using time series forecasting (arima), in: 2021 4th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), IEEE, 2021, pp. 598–602.
113. N. Latif, J. D. Selvam, M. Kapse, V. Sharma, V. Mahajan, Comparative performance of lstm and arima for the short-term prediction of bitcoin prices, *Australasian Accounting, Business and Finance Journal* 17 (1) (2023) 256–276.
114. G. Kim, D.-H. Shin, J. G. Choi, S. Lim, A deep learning-based cryptocurrency price prediction model that uses on-chain data, *IEEE Access* 10 (2022) 56232–56248.
115. Lim, Bryan & Arık, Sercan & Loeff, Nicolas & Pfister, Tomas. (2021). Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*. 37. 10.1016/j.ijforecast.2021.03.012.
116. Zhou, Haoyi & Zhang, Shanghang & Peng, Jieqi & Zhang, Shuai & Li, Jianxin & Xiong, Hui & Zhang, Wancai. (2021). Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. *Proceedings of the AAAI Conference on Artificial Intelligence*. 35. 11106-11115. 10.1609/aaai.v35i12.17325.
117. Piao, Xihao & Chen, Zheng & Murayama, Taichi & Matsubara, Yasuko & Sakurai, Yasushi. (2024). Fredformer: Frequency Debaised Transformer for Time Series Forecasting. 10.48550/arXiv.2406.09009.



118. Yu, Yongbo & Yu, Weizhong & Nie, Feiping & Li, Xuelong. (2024). PRformer: Pyramidal Recurrent Transformer for Multivariate Time Series Forecasting. 10.48550/arXiv.2408.10483.
119. Wang, Chaojie & Chen, Yuanyuan & Zhang, Shuqi & Zhang, Qihui. (2022). Stock market index prediction using deep Transformer model. *Expert Systems with Applications*. 208. 118128. 10.1016/j.eswa.2022.118128.
120. Ferdus, Mst & Anjum, Nishat & Nguyen, Tuan & Jisan, Afjal & Raju, Md Azad Hossain. (2024). The Influence of Social Media on Stock Market: A Transformer-Based Stock Price Forecasting with External Factors. *Journal of Computer Science and Technology Studies*. 6. 189-194. 10.32996/jcsts.2024.6.1.20.
121. Muhammad, T., Aftab, A.B., Ahsan, M., Muhu, M.M., Ibrahim, M., Khan, S.I., Alam, M.S. (2022). Transformer-Based Deep Learning Model for Stock Price Prediction: A Case Study on Bangladesh Stock Market. *arXiv 2022*, arXiv:2208.08300.
122. Sridhar, S and Sanagavarapu, S. (2021). Multi-head self-attention transformer for dogecoin price prediction. In *Proceedings of the 2021 14th International Conference on Human System Interaction (HSI)*, Gdansk, Poland, 8–10. 1–6.
123. Tanwar, Ayush & Kumar, Vinod. (2022). Prediction of Cryptocurrency prices using Transformers and Long Short term Neural Networks. 1-4. 10.1109/ICICCSP53532.2022.9862436.
124. Farooq, Arslan & Uddin, M. Irfan & Azeemi, Muhammad & Alarood, Ala & Alsolami, Eesa & Habibullah, Safa. (2024). Interpretable Multi-Horizon Time Series Forecasting of Cryptocurrencies by Leverage Temporal Fusion Transformer. *Heliyon*. 10. e40142. 10.1016/j.heliyon.2024.e40142.
125. Z. Zhang, S. Zohren and S. Roberts, "DeepLOB: Deep Convolutional Neural Networks for Limit Order Books," in *IEEE Transactions on Signal Processing*, vol. 67, no. 11, pp. 3001-3012, 1 June 1, 2019, doi: 10.1109/TSP.2019.2907260.
126. L. Zheng and T. Yu, "TCN-LOB: Temporal Convolutional Network for Limit Order Books," 2023 2nd International Conference on Robotics, Artificial Intelligence

- and Intelligent Control (RAIIC), Mianyang, China, 2023, pp. 372-375, doi: 10.1109/RAIIC59453.2023.10280898.
127. Z. Liu, C. -W. Sham, L. Ma and C. Fu, "ViT-LOB: Efficient Vision Transformer for StockPrice Trend Prediction Using Limit Order Books," 2024 10th International Conference on Applied System Innovation (ICASI), Kyoto, Japan, 2024, pp. 436-438, doi: 10.1109/ICASI60819.2024.10547868.
  128. Jin, K., Liu, X., & Zhang, W. The Analysis of Factors Affecting Bitcoin Price. BCP Business & Management, 2022, vol. 24, pp. 23-33. DOI: 10.54691/bcpbm.v24i.1423.
  129. Rosenbaum, R. R., & Rubin, D. B. The Central Role of the Propensity Score in Observational Studies for Causal Effects. Biometrika, 1983, vol. 70, iss. 1, pp. 41-55. DOI:10.1093/biomet/70.1.41.
  130. Rosenbaum, P. R., & Rubin, D. B. Reducing Bias in Observational Studies Using Subclassification on the Propensity Score. Journal of the American Statistical Association, 1984, vol. 79, no. 387, pp. 516-524. DOI: 10.2307/2288398.
  131. Chernozhukov, V., Chetverikov, D., Demirer, M., Duflo, E., Hansen, C., Newey, W., & Robins, J. Double/debiased machine learning for treatment and structural parameters. The Econometrics Journal, 2018, vol. 21, iss. 1, pp. 1-68. DOI: 10.1111/ectj.12097.
  132. Naser, M. Z., & Çiftçioğlu, A. Ö. Causal discovery and inference for evaluating fire resistance of structural members through causal learning and domain knowledge. Structural Concrete, 2023, vol. 24, iss. 3, pp. 3314-3328. DOI: 10.1002/suco.202200525.
  133. Nogueira, A. R., Pugnana, A., Ruggieri, S., Pedreschi, D., & Gama, J. Methods and tools for causal discovery and causal inference. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2020, vol. 12, iss. 2, article no. e1449. DOI: 10.1002/widm.1449.
  134. Mokni, K., & Ajmi, A. N. Cryptocurrencies vs. US dollar: Evidence from causality in quantiles analysis. Economic Analysis and Policy, 2021, vol. 69, pp. 238-252. DOI: 10.1016/j.eap.2020.12.011.

135. Dastgir, S., Demir, E., Downing, G., Gozgor, G., & Lau, C. K. M. The causal relationship between Bitcoin attention and Bitcoin returns: Evidence from the Copula-based Granger causality test. *Finance Research Letters*, 2019, vol. 28, pp. 160-164. DOI: 10.1016/j.frl.2018.04.019.
136. Bloomfield, Robert & O'Hara, Maureen & Saar, Gideon. (2009). How Noise Trading Affects Markets: An Experimental Analysis. *Review of Financial Studies*. 22. 2275-2302. 10.1093/rfs/hhn102.
137. Saud, Arjun & Shkaya, Subarna. (2024). Technical Indicator Empowered Intelligent Strategies to Predict Stock Trading Signals. *Journal of Open Innovation: Technology, Market, and Complexity*. 10. 100398. 10.1016/j.joitmc.2024.100398.
138. M. L. de Prado, *Advances in Financial Machine Learning*. New Jersey: John Wiley & Sons, 2018.
139. Lubba, Carl H., et al. "catch22: Canonical time-series characteristics." *Data Mining and Knowledge Discovery* 33.6 (2019): 1821-1852.  
<https://link.springer.com/article/10.1007/s10618-019-00647-x>
140. Dempster, A., Petitjean, F. and Webb, G.I., 2020. ROCKET: exceptionally fast and accurate time series classification using random convolutional kernels. *Data Mining and Knowledge Discovery*, 34(5), pp.1454-1495.
141. Zhao et. al, Convolutional neural networks for time series classification, *Journal of Systems Engineering and Electronics*, 28(1):2017.
142. Wolpert, David H. "Stacked generalization." *Neural networks* 5.2 (1992): 241-259.
143. Hyndman, R.J., & Athanasopoulos, G. (2021) *Forecasting: principles and practice*, 3rd edition, OTexts: Melbourne, Australia. [OTexts.com/fpp3](https://otexts.com/fpp3). Accessed on 15.05.2025
144. McClish DK. Analyzing a portion of the ROC curve. *Med Decis Making*. 1989 Jul-Sep;9(3):190-5. doi: 10.1177/0272989X8900900307. PMID: 2668680.
145. Taherdoost, Hamed, and Mitra Madanchian. 2023. "Multi-Criteria Decision Making (MCDM) Methods and Concepts" *Encyclopedia* 3, no. 1: 77-87.  
<https://doi.org/10.3390/encyclopedia3010006>

146. Binance – Cryptocurrency Exchange for Bitcoin, Ethereum & Altcoins. Available at: <https://www.binance.com> (accessed 15.11.2024).
147. CCXT – CryptoCurrency eXchange Trading Library. Available at: <https://github.com/ccxt/ccxt> (accessed 15.11.2024).
148. Numpy – The fundamental package for scientific computing with Python. Available at: <https://numpy.org> (accessed 15.11.2024).
149. Pandas – Python Data Analysis Library. Available at: <https://pandas.pydata.org> (accessed 15.11.2024).
150. Plotly – Data Apps for Production. Available at: <https://plotly.com> (accessed 15.11.2024).
151. Ali, Z., Bhaskar, S. B., & Sudheesh, K. Descriptive Statistics: Measures of Central Tendency, Dispersion, Correlation and Regression. Airway, 2019, vol. 2, iss. 3, pp. 120-125. DOI: 10.4103/ARWY.ARWY\_37\_19.
152. Baillie, R. T., & DeGennaro, R. P. Stock Returns and Volatility. The Journal of Financial and Quantitative Analysis, 1990, vol. 25, no. 2, pp. 203-214. DOI: 10.2307/2330824.
153. Al-kassab, M., & Majeed, A. The use of two-sample t-test in the real data. Advances and Applications in Statistics, 2022, vol. 81, pp. 13-22. DOI: 10.17654/0972361722071.
154. Zverev A. I. Handbook of Filter Synthesis. Wiley, 1967. 592 p.
155. Robert C. M. Design Principles and Design Patterns, 2000. pp. 22-24.

## ДОДАТОК А

## Топ 10 комбінацій за Sharpe Ratio для довгих та коротких позицій

В таблиці А.1 зображено топ 10 комбінацій за Sharpe Ratio для довгих позицій, а в таблиці А.2 топ 10 комбінацій за Sharpe Ratio для коротких позицій. Можна побачити, що в більшості випадків натреновані класифікатори демонструють кращі метрики, аніж Dummy модель.

Таблиця А.1

## Топ 10 комбінацій за Sharpe Ratio для довгих позицій

Пара	Інтервал	Показник	Вікно	Модель	Roc Auc	Precision	Recall	Sharpe Ratio	Сума доходів, %
BTC/USDT	1 година	Мех. ковзна	128	Catch22	0.628	0.65	0.69	2.0	229.7
BTC/USDT	30 хвилин	VWMA	32	Rocket	0.53	0.5	0.53	1.99	317.7
BTC/USDT	1 година	Мех. ковзна	128	Stacking	0.585	0.66	0.620	1.92	214.3
DOGE/USD T	1 година	Мех. ковзна	64	Catch22	0.54	0.66	0.16	1.65	189.1
ETH/USDT	2 години	Мех. ковзна	64	Rocket	0.58	0.61	0.64	1.65	316.1
BTC/USDT	1 година	VWMA	32	Rocket	0.51	0.5	0.51	1.59	250.1
BTC/USDT	1 година	Мех. ковзна	128	Dummy	0.5	0.56	1.0	1.54	204.3
BTC/USDT	30 хвилин	Мех. ковзна	64	Rocket	0.523	0.52	0.56	1.53	221.6
BTC/USDT	30 хвилин	Мех. ковзна	64	Dummy	0.5	0.49	1.0	1.5	260.8
ETH/USDT	30 хвилин	MAS Buy	128	Catch22	0.57	0.55	0.57	1.49	217.5

Таблиця А.2

Топ 10 комбінацій за Sharpe Ratio для коротких позицій

Пара	Інтер-вал	Показ-ник	Вікно	Модель	Roc Auc	Prec-ision	Rec-all	Sharpe Ratio	Сума доходів, %
DOGE/USD DT	1 година	VWMA	128	Rocket	0.49	0.55	0.63	0.7	146.1
XRP/ USD T	30 хвилин	MFI	128	Summary	0.55	0.55	0.64	0.68	75.3
BTC/ USD T	2 години	Мех. ковзна	64	Stacking	0.58	0.46	0.14	0.66	42.1
ETH/ USD T	2 години	VWMA	128	TimeCNN	0.63	0.55	0.82	0.64	95.5
DOGE/USD DT	1 година	VWMA	128	Dummy	0.5	0.56	1.0	0.59	99.5
BNB/ USD T	30 хвилин	MFI	64	Stacking	0.5	0.55	0.17	0.57	59.6
DOGE/USD DT	1 година	VWMA	128	TimeCNN	0.51	0.56	1.0	0.56	87.8
ETH/ USD T	30 хвилин	MAS Sell	32	Catch22	0.54	0.55	0.4	0.52	38.5
ETH/ USD T	1 година	MAS Buy	16	TimeCNN	0.45	0.4	0.55	0.5	63.3
ETH/ USD T	30 хвилин	VWMA	32	Catch22	0.52	0.45	0.22	0.49	103.1

## ДОДАТОК Б

### Екранні форми програмної реалізації методу аналізу та прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання

На рис. Б.1 зображено інтерфейс користувача програмної реалізації. У верхній панелі розташовані меню вибору торгової пари (наприклад, BTC/USDT), інтервалу (наприклад, 5 хвилин), показник механістичного підходу на подіях якого була натренована модель машинного навчання (наприклад, MAS Volume Buy, mas\_buy), меню вибору Long або Short позиції) та вибір моделі. У правому верхньому куті вибір світлої або темної теми. Графічна частина складається з шести (6) графіків:

- 1) OHLCV (свічковий графік) з синіми трикутниками, які відповідають прогнозам моделі, ймовірності яких вищі за заданий поріг (графік 6);
- 2) графік з сумарними ринковими обсягами (Volume);
- 3) графік з дельтою ринкових обсягів (Vol Delta);
- 4) графік GMI показників;
- 5) графік MAS показників;
- 6) ймовірності прогнозів моделі разом із заданим порогом (пунктирна лінія).



Рис. Б.1 – Інтерфейс користувача програмної реалізації

Якщо обрати коротку позицію, то трикутники на графіку 1 (рис. Б.2) стануть помаранчевого кольору та будуть повернуті вниз. На рис. Б.3 зображено інтерфейс API.



Рис. Б.2 – Інтерфейс користувача програмної реалізації, приклад Short позицій

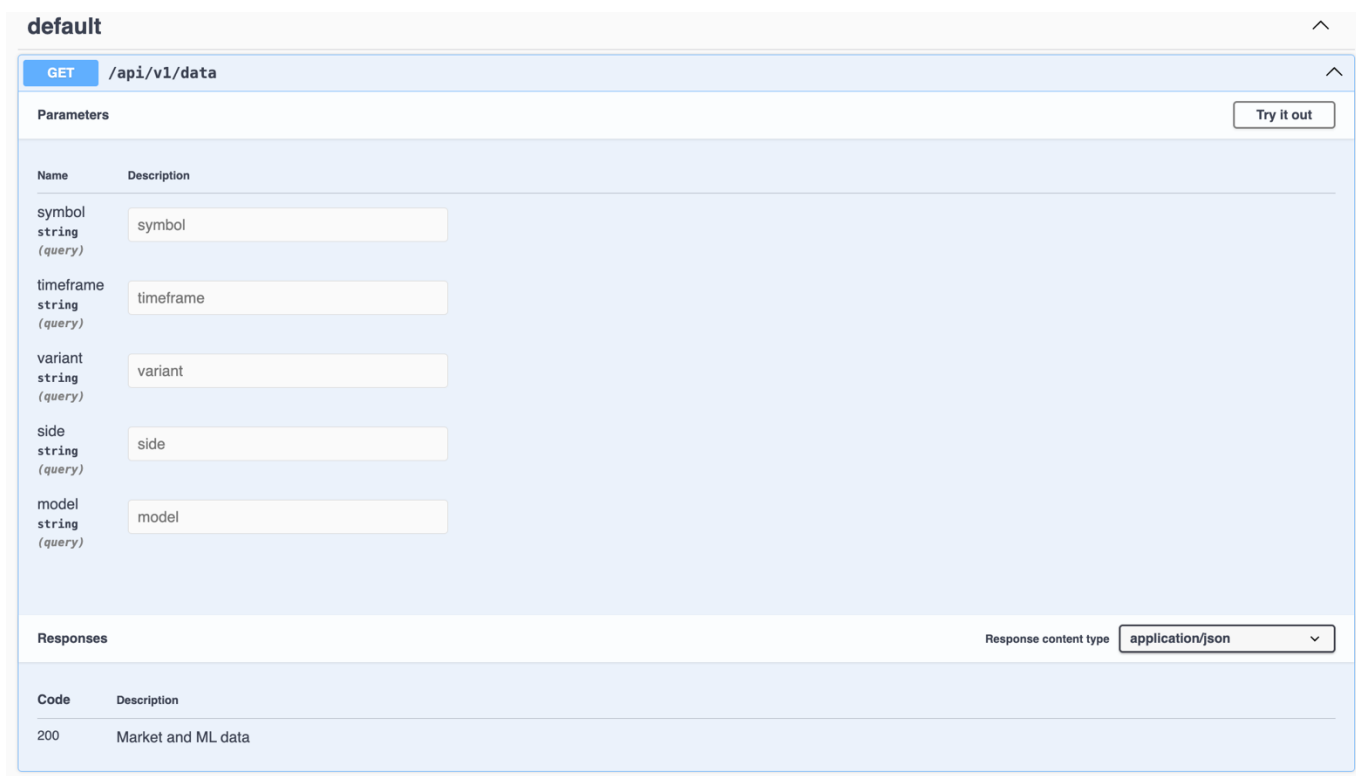


Рис. Б.3 – Інтерфейс API



## ДОДАТОК В

**NumPy імплементація механістичної ковзної та  
показника поглинання імпульсу**

```

import numpy as np

def calc_rolling_percentiles(arr, window, p1, p2):
    out_p1 = np.zeros_like(arr, dtype=np.float64)
    out_p2 = np.zeros_like(arr, dtype=np.float64)
    for i in range(len(arr)):
        if i < window - 1:
            out_p1[i] = np.nan
            out_p2[i] = np.nan
        else:
            w_arr = arr[i - window + 1: i + 1]
            out_p1[i] = np.percentile(w_arr, p1)
            # -1.0: нам потрібне лише один процентиль
            if p2 != -1.0:
                out_p2[i] = np.percentile(w_arr, p2)
    return out_p1, out_p2

def calculate_mas(close, volume, window):
    p25_c, p75_c = calc_rolling_percentiles(close, window, 25.0, 75.0)
    p75_v, _ = calc_rolling_percentiles(volume, window, 75.0, -1.0)

    mas = np.zeros_like(volume, dtype=np.int32)
    for i in range(len(volume)):
        if np.isnan(p25_c[i]) or np.isnan(p75_v[i]):
            mas[i] = 0
        else:
            if close[i] < p25_c[i] and volume[i] > p75_v[i]:
                mas[i] = 1 # Лонг
            elif close[i] > p75_c[i] and volume[i] > p75_v[i]:
                mas[i] = -1 # Шорт
            else:
                mas[i] = 0
    return mas

```

```

def calculate_gmi(close, volume, window):
    gmi = np.zeros_like(close, dtype=np.float64)
    for i in range(len(close)):
        if i < window:
            gmi[i] = np.nan
        else:
            w_vol_mean = np.mean(volume[i - window + 1 : i + 1])
            if w_vol_mean == 0 or window == 0:
                gmi[i] = 0
            else:
                vol_ratio = volume[i] / w_vol_mean
                price_diff = close[i] - close[i - window]
                gmi[i] = vol_ratio * (price_diff / window)
    return gmi

def calculate_gmi_sma(gmi, fast, slow):
    events = np.zeros_like(gmi, dtype=np.int32)
    fast_sma = np.zeros_like(gmi, dtype=np.float64)
    slow_sma = np.zeros_like(gmi, dtype=np.float64)

    for i in range(len(gmi)):
        if i < slow - 1 or np.isnan(gmi[i]):
            fast_sma[i] = np.nan
            slow_sma[i] = np.nan
        else:
            fast_sma[i] = np.mean(gmi[i - fast + 1 : i + 1])
            slow_sma[i] = np.mean(gmi[i - slow + 1 : i + 1])

    # Перетин ковзних
    if i > 0 and not np.isnan(fast_sma[i-1]) and not np.isnan(slow_sma[i-1]):
        if fast_sma[i-1] <= slow_sma[i-1] and fast_sma[i] > slow_sma[i]:
            events[i] = 1
        elif fast_sma[i-1] >= slow_sma[i-1] and fast_sma[i] < slow_sma[i]:
            events[i] = -1
    return events

```

## ДОДАТОК Г

## Акти впровадження наукових досліджень дисертаційної роботи

ЗАТВЕРДЖУЮ  
Перший проректор  
Державного університету  
інформаційно-комунікаційних  
технологій

Член-кореспондент НАН України,  
доктор технічних наук, лауреат  
Державної премії України в галузі  
науки і техніки, Заслужений діяч  
науки і техніки України

Олександр КОРЧЕНКО  
«18» вересня 2026 р.

## АКТ

впровадження в освітній процес Державного університету інформаційно-комунікаційних технологій наукових результатів **Цапро Ігоря Вікторовича**, одержаних під час проведення дисертаційного дослідження на здобуття наукового ступеня доктора філософії за спеціальністю 121 Інженерія програмного забезпечення, галузі знань 12 Інформаційні технології на тему: «Метод аналізу та прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання»

Комісія у складі:

голови комісії – директора Навчально-наукового інституту інформаційних технологій, д.т.н., професора Катерини НЕСТЕРЕНКО;

членів комісії:

завідувача кафедри Інженерії програмного забезпечення Навчально-наукового інституту інформаційних технологій, д.т.н., професора Ірини ЗАМРІЙ;

завідувача кафедри Інформаційних систем та технологій Навчально-наукового інституту інформаційних технологій, д.т.н., професора Каміли СТОРЧАК;

професора кафедри Інженерії програмного забезпечення Навчально-наукового інституту інформаційних технологій, к.ф.-м.н., доцента Володимира САДОВЕНКА;

провела роботу щодо визначення фактичного впровадження результатів наукового дослідження здобувача наукового ступеня доктора філософії Цапро І. В. в освітній процес Державного університету інформаційно-комунікаційних технологій.

У результаті проведеної роботи комісія встановила:

1. Наукові результати, одержані здобувачем, використовуються при підготовці здобувачів освітнього рівня бакалавр за спеціальністю 121 Інженерія програмного забезпечення освітньої програми «Інженерія програмного забезпечення». Зокрема:

1.1. Удосконалений метод механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці, використовується у навчальному процесі під час проведення лекційних та практичних занять із дисципліни «Технології Big Data».

1.2. Удосконалений метод прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу (механістичної ковзної та показника MAS) із застосуванням ансамблевого машинного навчання та класифікації прибутковості подій за методом потрібних бар'єрів, використовується у навчальному процесі під час проведення лекційних та практичних занять із дисципліни «Технології Big Data».

1.3. Розроблений показник поглинання імпульсу (Momentum Absorption Score, MAS), який ґрунтується на статистичному виявленні зон низької волатильності при аномально високих торгових обсягах за допомогою z-оцінок та процентильного аналізу і є складовою удосконаленого методу механістичного аналізу динаміки криптовалютних активів, застосовується в межах дисципліни «Програмування» під час вивчення принципів алгоритмізації, програмної реалізації математичних обчислень та обробки масивів даних.

2. Вказані наукові результати Цапро І. В. представлені у формі окремих навчальних тем, прикладів програмного коду та кейсів у методичних матеріалах до лекцій і практичних занять згаданих дисциплін, які проводяться в Державному університеті інформаційно-комунікаційних технологій на кафедрі Інженерії програмного забезпечення.

Голова комісії:

Директор Навчально-наукового інституту інформаційних технологій,  
д.т.н., професор

Катерина НЕСТЕРЕНКО

Члени комісії:

Завідувач кафедри Інженерії програмного забезпечення  
д.т.н., професор

Ірина ЗАМРІЙ

Завідувач кафедри Інформаційних систем та технологій  
д.т.н., професор


Каміла СТОРЧАК

Професор кафедри Інженерії програмного забезпечення  
к.ф.-м.н., доцент

Володимир САДОВЕНКО



ЗАТВЕРДЖУЮ  
Фізична особа-підприємець  
Новіцька Анна Валеріївна

 НОВІЦЬКА А.В.  
«11» травня 2026 р.

### АКТ

впровадження результатів дисертаційної роботи Цапро Ігоря Вікторовича на тему: «Метод аналізу та прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання»

Запропоновані наукові дослідження Цапро І. В. спрямовані на розробку практичних рекомендацій в практичній діяльності ФОП Новіцька Анна Валеріївна при реалізації проекту з токенизації активів.

В ході роботи було впроваджено:

1) метод механістичного аналізу динаміки криптовалютних активів за рахунок інтеграції даних роздільних обсягів ринкових покупок, продажів та їхньої абсолютної різниці, з метою моделювання динаміки попиту та пропозиції токenu компанії;

2) метод прогнозування динаміки ринку криптовалют за рахунок впровадження етапу інтелектуальної фільтрації торгових сигналів, сформованих на основі показників механістичного аналізу (механістичної ковзної та показника MAS) із застосуванням ансамблевого машинного навчання та класифікації прибутковості подій за методом потрібних бар'єрів, для оцінки цінової динаміки токenu компанії на прогнозному горизонті 3, 6 та 12 місяців;

3) архітектурні рішення реалізації методів аналізу та прогнозування динаміки ринку криптовалют у складі єдиної інтелектуальної системи за рахунок впровадження модульної монолітної структури з розділеними контурами навчання та інференсу та програмно-технологічні засоби із застосуванням ЛІТ-компіляції та паралелізації обчислень.

Застосування запропонованих методів дозволило:

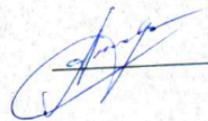
1. Підвищити обґрунтованість бізнес-рішень у комунікації з інвесторами, партнерами по біржі та розробки токеноміки для майбутніх клієнтів;

2. Зменшити відсоток хибно позитивних оцінок цінової динаміки токenu компанії у наступні 3, 6 та 12 місяців на 11%.

3. Скоротити час на аналіз ринкових даних на 40%.

Результати дисертаційного дослідження Цапро І. В. на тему «Метод аналізу та прогнозування динаміки ринку криптовалют на основі механістичного підходу та машинного навчання» мають практичну цінність і можуть бути рекомендовані для впровадження на інших підприємствах галузі інформаційних технологій для скорочення часу на аналіз ринкових даних та підвищення якості бізнес-рішень.

ФОП Новіцька Анна Валеріївна



НОВІЦЬКА А.В.

## ДОДАТОК Д

### Список опублікованих праць за темою дисертації

1. Цапро І.В. Адаптація механістичного підходу до аналізу ринку криптовалют. Зв'язок, 2023, № 1 (161), с. 47-51. DOI: 10.31673/2412-9070.2023.014647.
2. Tsapro, I. A comparative study between price-driven and mechanistic moving averages using causal analysis on Bitcoin historical data. Radioelectronic and Computer Systems, 2025, vol 2025, no. 1, pp. 44-57. DOI: 10.32620/reks.2025.1.03.
3. Цапро І. В., Золотухіна О. А. Вдосконалення механістичного підходу з використанням даних ринкових обсягів біткоїна. Зв'язок, 2025, № 3 (175), с. 87-94. DOI: 10.31673/2412-9070.2025.026142.
4. Цапро І. В. Застосування машинного навчання в задачі відсіювання неефективних торгових сигналів згенерованих показниками механістичного підходу. Зв'язок, № 5 (177), 2025, с. 79-86. DOI: 10.31673/2412-9070.2025.051067.
5. Цапро І. В., Золотухіна О. А. Програмна реалізація показника поглинання імпульсу як статистичного інструменту на ринку біткоїна. Зв'язок, 2026, № 3. DOI: 10.31673/2412-9070.2026.318113.
6. Цапро І.В., Золотухіна О.А. Актуальність механістичного підходу та машинного навчання для аналізу ринку криптовалют. Збірник тез. Міжнародна науково-практична конференція «Сучасні аспекти діджиталізації та інформатизації в програмній та комп'ютерній інженерії», 1 – 3 червня 2023 року, ДУІКТ, м. Київ, с. 80-81. URL: [https://duikt.edu.ua/uploads/n\\_11337\\_64054605.pdf](https://duikt.edu.ua/uploads/n_11337_64054605.pdf).
7. Цапро І.В., Золотухіна О.А. Дизайн архітектури програмного забезпечення виявлення аномалій для підтримки ухвалення рішень на ринку криптовалют. Збірник тез. Всеукраїнська науково-технічна конференція «Застосування програмного забезпечення в інформаційно-комунікаційних технологіях», 24 квітня 2024 року, ДУІКТ, м. Київ, с. 96-98. URL: [https://duikt.edu.ua/uploads/p\\_2661\\_45497999.pdf](https://duikt.edu.ua/uploads/p_2661_45497999.pdf).
8. Цапро І.В., Золотухіна О.А. Порівняння методів аналізу торгових обсягів у середовищі python. Збірник тез. Всеукраїнська, науково-практична конференція молодих учених та студентів «Інформаційні технології в освіті, техніці та

промисловості», 10 жовтня 2024 року, ІФНТУНГ, м. Івано-Франківськ, с. 169-171. URL: [https://drive.google.com/file/d/1XrD-obOLO\\_MBz3DuotBYS4S7fKqycmFS/view](https://drive.google.com/file/d/1XrD-obOLO_MBz3DuotBYS4S7fKqycmFS/view).

9. Цапро І.В., Золотухіна О.А. Зменшення часу перетренування моделей машинного навчання. Збірник тез. II всеукраїнська науково-технічна конференція «Технологічні горизонти: дослідження та застосування інформаційних технологій для технологічного прогресу України і світу», 18 листопада 2024 року, ДУІКТ, м. Київ, с. 77-79. URL: [https://duikt.edu.ua/uploads/p\\_2661\\_83654085.pdf](https://duikt.edu.ua/uploads/p_2661_83654085.pdf).

10. Цапро І.В., Золотухіна О.А. Оцінка ефективності алгоритмічних торгових стратегій у розрізі висхідного та спадного трендів. Збірник тез. Всеукраїнська науково-технічна конференція «Застосування програмного забезпечення в ІКТ», 24 квітня 2025 року, ДУІКТ, м. Київ, с. 554-556. URL: [https://duikt.edu.ua/uploads/p\\_2779\\_56719466.pdf](https://duikt.edu.ua/uploads/p_2779_56719466.pdf).

11. Цапро І.В., Золотухіна О.А. Застосування алгоритмів машинного навчання в прогнозуванні напрямку руху цін криптоактивів. Збірник тез. Всеукраїнська науково-технічна конференція "Виклики та рішення в програмній інженерії", 26 листопада 2025 року, ДУІКТ, м. Київ, с. 355-357. URL: [https://duikt.edu.ua/uploads/p\\_2779\\_29705833.pdf](https://duikt.edu.ua/uploads/p_2779_29705833.pdf).

12. Цапро І.В., Золотухіна О.А. Оптимізація обчислень показника поглинання імпульсу методами динамічної компіляції та кешування. Збірник тез. VII Всеукраїнська науково-технічна конференція «Застосування програмного забезпечення в інформаційно-комунікаційних технологіях», 23 квітня 2026 року, ДУІКТ, м. Київ, с. 361-363, URL: [https://duikt.edu.ua/uploads/p\\_3086\\_61927919.pdf](https://duikt.edu.ua/uploads/p_3086_61927919.pdf).