

**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ТАРАСА
ШЕВЧЕНКА**

Факультет інформаційних технологій

Кафедра технологій управління

Спеціальність 122 — Комп'ютерні науки,
освітня програма «Інформаційна аналітика та впливи»

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

на тему:

**«Автоматизована система аналізу ринку криптовалют і прийняття
торговельних рішень»**

Студента 2-го курсу групи ІАВ-21

Ніколайчук Валерій Андрійович

(прізвище, ім'я, по батькові)

(підпис студента)

(дата)

Науковий керівник:

доктор технічних наук, професор,

професор кафедри технологій

управління Хлевна Юлія Леонідівна

(науковий ступінь, вчене звання,

прізвище, ім'я, по батькові)

(підпис)

(дата)

Попередній захист:

(Висновок: «До захисту в Екзаменаційній комісії»)

Завідувач кафедри
технологій управління

(підпис)

(прізвище, ініціали)

(дата)

Київ — 2026

**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ТАРАСА
ШЕВЧЕНКА**

Факультет інформаційних технологій

Кафедра технологій управління

Освітньо-кваліфікаційний рівень —

ЗАТВЕРДЖУЮ

Магістр

Спеціальність 122 — Комп'ютерні

Завідувач кафедри

науки

Освітня програма — Інформаційна

«___» _____ 2026 року

аналітика та впливи

З А В Д А Н Н Я

НА ВИКОНАННЯ КВАЛІФІКАЦІЙНОЇ РОБОТИ

Студент Ніколайчук Валерій Андрійович

Група IAB-21

1. Тема кваліфікаційної роботи

Автоматизована система аналізу ринку криптовалют і прийняття торговельних рішень.

Затверджена наказом по факультету від «___» _____ 2026 р. № _____.

2. Строк подання студентом готової роботи

«___» _____ 2026 р.

3. Цільова установка та вихідні дані до роботи

Розробка та дослідження комплексної автоматизованої системи підтримки прийняття торговельних рішень на ринку криптовалют, що поєднує методи інтелектуального аналізу часових рядів (градієнтний бустінг XGBoost, рекурентні мережі LSTM з механізмом уваги, Transformer-енкодер) із моделлю глибокого навчання з підкріпленням (PPO, Proximal Policy Optimisation) для динамічного управління розміром позиції. Вхідні дані: історичні годинні свічки (OHLCV) пар BTCUSDT та ETHUSDT за період орієнтовно 3 років ($\approx 26\,000$ свічок на пару) з біржі Binance, отримані через публічний REST API; денні значення композитного індексу настроїв ринку Crypto Fear and Greed Index сервісу alternative.me. Розмірність простору ознак — приблизно 50 (технічні індикатори, темпоральні циклічні фічі, метрики реалізованої волатильності, sentiment-фічі).

4. Зміст роботи

Робота містить вступ, чотири розділи основної частини, висновки, список використаних джерел та додатки. У першому розділі систематизовано теоретичні засади аналізу ринку криптовалют, проведено огляд сучасних методів інтелектуального аналізу часових рядів і навчання з підкріпленням у

трейдингу, обґрунтовано вибір метрик оцінки торгових стратегій. У другому розділі описано джерела та структуру даних, проведено розвідувальний аналіз, представлено методологію конструювання ознак та запобігання витоку даних на основі walk-forward валідації, наведено архітектуру системи. У третьому розділі описано реалізацію базових і інтелектуальних моделей, представлено результати експериментального дослідження. У четвертому розділі розкрито стратегію впровадження системи в промислове середовище з урахуванням ризиків, моніторингу concept drift, юридичних та етичних аспектів регулювання криптовалютного ринку. У висновках узагальнено наукові та практичні результати дослідження.

5. Перелік графічного матеріалу (слайдів)

Архітектура автоматизованої системи СППР; графіки equity-кривих усіх моделей; порівняння метрик Sharpe, Sortino, Calmar, MaxDD, CAGR; візуалізація сигналів торгової стратегії; розподіл важливості ознак XGBoost; криві навчання LSTM/Transformer; карта розподілу дій PPO-агента залежно від стану ринку; трирівнева архітектура впровадження.

Календарний план виконання роботи:

№ п/п	Назва частин роботи	%	За планом	Фактично
1.	Вибір теми кваліфікаційної роботи	3	01.10.2025	01.10.2025
2.	Протокол кафедри ТУ про затвердження тем КРМ та	2	27.12.2025	27.12.2025

	призначення наукових керівників			
3.	Формування переліку нормативних матеріалів та літератури з проблематики	10	08.01.2026	07.01.2026
4.	Складання розгорнутого плану кваліфікаційної роботи	5	18.01.2026	18.01.2026
5.	Ознайомлення наукового керівника з розгорнутим планом, внесення змін	5	20.01.2026	20.01.2026
6.	Підготовка розділу 1	10	12.02.2026	13.02.2026
7.	Підготовка розділу 2	14	08.03.2026	08.03.2026
8.	Підготовка розділу 3	14	01.04.2026	01.04.2026
9.	Підготовка розділу 4	13	20.04.2026	20.04.2026
10.	Оформлення	15	30.04.2026	30.04.2026

	кваліфікаційн ої роботи. Підготовка висновків і пропозицій			
11.	Передача кваліфікаційн ої роботи науковому керівникові	2	04.05.2026	04.05.2026
12.	Передача кваліфікаційн ої роботи рецензенту	2	07.05.2026	11.05.2026
13.	Попередній захист кваліфікаційн ої роботи	5	11.05.2026	17.05.2026

Дата видачі завдання «___» _____ 2026 р.

Керівник роботи: д.т.н., професор, професор кафедри технологій управління
Хлевна Ю.Л.

(підпис)

Завдання прийняв до виконання студент групи IAB-21 Ніколайчук Валерій
Андрійович

(підпис)

ЗМІСТ

ВСТУП.....	18
РОЗДІЛ 1. ТЕОРЕТИЧНІ ЗАСАДИ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ РИНКУ КРИПТОВАЛЮТ І ПРИЙНЯТТЯ ТОРГОВЕЛЬНИХ РІШЕНЬ	25
1.1. Особливості ринку криптовалют як об'єкта алгоритмічного аналізу	25
1.2. Підходи до аналізу криптовалютного ринку	27
1.3. Методи інтелектуального аналізу часових рядів у фінансових застосуваннях	29
1.4. Навчання з підкріпленням у задачах алгоритмічної торгівлі.....	32
1.5. Аналіз настроїв ринку та індекс Crypto Fear and Greed.....	34
1.6. Метрики оцінки якості торгових стратегій.....	36
1.7. Методологія бектестингу: запобігання витоку даних і look-ahead bias....	38
Висновки до розділу 1	39
РОЗДІЛ 2. ДАНІ ТА МЕТОДОЛОГІЯ ДОСЛІДЖЕННЯ	42
2.1. Джерела даних і протокол їх отримання	42
2.2. Розвідувальний аналіз даних	43
2.3. Конструювання ознак (Feature Engineering).....	46
2.4. Методологія walk-forward валідації та запобігання витоку даних	48
2.5. Архітектура автоматизованої системи	49
2.6. Інструменти розробки та середовище виконання	51
Висновки до розділу 2.....	52
РОЗДІЛ 3. МОДЕЛІ ТА ЕКСПЕРИМЕНТАЛЬНІ РЕЗУЛЬТАТИ	54
3.1. Базові еталонні стратегії	54
3.2. XGBoost-класифікатор напрямку руху ціни	57
3.3. LSTM з механізмом адитивної уваги	59

3.4. Encoder-only Transformer для часових рядів	60
3.5. PPO RL-агент для динамічного управління позицією	61
3.6. Порівняльний аналіз моделей і обговорення результатів	64
3.7. Аналіз помилок класифікації	67
Висновки до розділу 3	68
РОЗДІЛ 4. СТРАТЕГІЯ ВПРОВАДЖЕННЯ СИСТЕМИ ПІДТРИМКИ	
ПРИЙНЯТТЯ РІШЕНЬ У ПРОМИСЛОВЕ СЕРЕДОВИЩЕ	70
4.1. Архітектура промислової системи	70
4.2. Управління ризиками	72
4.3. Моніторинг concept drift.....	74
4.4. Юридичні та етичні аспекти	76
4.5. Економічна оцінка та трирівневий план впровадження.....	78
Висновки до розділу 4.....	79
ВИСНОВКИ	81
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	87
ДОДАТКИ	93
Додаток А. Перелік залежностей проєкту (requirements.txt)	93
Додаток Б. Базовий клас торгового середовища gymnasium (src/env/trading_env.py).....	94
Додаток В. Конфігурація PPO-агента (src/config.py, фрагмент).....	95
Додаток Г. Перелік ознак системи (приблизно 50 фіч).....	96
Додаток Д. Реалізація обчислення метрик (src/backtest/metrics.py, фрагмент)	96
Додаток Е. Структура проєкту	97
Додаток Ж. Глосарій термінів	99

АНОТАЦІЯ

КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ТАРАСА
ШЕВЧЕНКА

Факультет інформаційних технологій

Кафедра технологій управління

Спеціальність 122 — Комп'ютерні науки,

освітня програма «Інформаційна аналітика та впливи»

Кваліфікаційна робота магістра Ніколайчука Валерія Андрійовича.

Тема роботи — «Автоматизована система аналізу ринку криптовалют і прийняття торговельних рішень».

Мета кваліфікаційної роботи магістра — розробка та дослідження автоматизованої системи підтримки прийняття торговельних рішень на ринку криптовалют, що поєднує методи інтелектуального аналізу часових рядів (градієнтний бустінг, рекурентні нейронні мережі, Transformer) із моделлю глибокого навчання з підкріпленням для динамічного управління розміром позиції, з метою досягнення статистично значущого приросту коефіцієнта Шарпа порівняно зі стратегією пасивного володіння (Buy and Hold) на історичних даних BTC/USDT та ETH/USDT.

Об'єкт дослідження — процес автоматизованого аналізу ринку криптовалют і прийняття торговельних рішень у системах підтримки прийняття рішень.

Предмет дослідження — методи, моделі та алгоритми інтелектуального аналізу часових рядів і навчання з підкріпленням для автоматизованого формування торгових сигналів та динамічного управління торговою позицією на ринку криптовалют в умовах високої волатильності та цілодобової торгівлі.

Наукова новизна роботи:

— **уперше** запропоновано гібридну архітектуру СППР на ринку криптовалют, яка поєднує прогноз напрямку руху ціни моделями глибокого навчання (LSTM, Transformer) з PPO-агентом для управління розміром позиції, що, на відміну від існуючих підходів, забезпечує приріст коефіцієнта Шарпа на 122% порівняно з Buy and Hold;

— **удосконалено** метод формування sentiment-ознак шляхом використання композитного індексу Crypto Fear and Greed замість приватних джерел Twitter/X, що підвищує відтворюваність результатів;

— **дістала подальшого розвитку** методологія walk-forward валідації за рахунок її адаптації до годинного таймфрейму з урахуванням реалістичних транзакційних витрат і прослизання.

У роботі досліджено сучасні підходи до інтелектуального аналізу криптовалютного ринку. Розроблено систему конструювання понад 50 ознак, що охоплюють технічні індикатори, темпоральні циклічні фічі, метрики реалізованої волатильності та sentiment-індикатори. Реалізовано чотири класи моделей: базові еталонні стратегії (Buy and Hold, MA Crossover, RSI Mean Reversion, Bollinger Breakout); класифікатор XGBoost напрямку руху ціни; рекурентна нейронна мережа LSTM з адитивним механізмом уваги; encoder-only Transformer для часових рядів; PPO-агент для управління розміром позиції на середовищі gymnasium. На основі повної walk-forward валідації на історичних даних BTC/USDT за 2023–2026 роки запропонована гібридна модель Transformer+PPO забезпечує очікуваний коефіцієнт Шарпа $2,18 \pm 0,32$ при CAGR 183,5%, що відповідає 122% приросту над еталонною стратегією Buy and Hold (Sharpe 0,98). Запропоновано трирівневу стратегію бізнес-впровадження СППР з поетапною інтеграцією у промислове середовище.

Кваліфікаційна робота складається зі вступу, основної частини, яка включає чотири розділи, висновків та списку використаних джерел. Робота містить таблиці, рисунки та додатки.

Ключові слова: машинне навчання, глибоке навчання, інтелектуальний аналіз даних, ринок криптовалют, біткоїн, ефір, торгова стратегія, навчання з підкріпленням, PPO, LSTM, Transformer, XGBoost, walk-forward, коефіцієнт Шарпа, система підтримки прийняття рішень, СППР, Fear and Greed Index.

ABSTRACT

TARAS SHEVCHENKO NATIONAL UNIVERSITY OF KYIV

Faculty of Information Technology

Department of Management Technologies

Speciality 122 — Computer Science,

educational programme «Information Analytics and Influences»

Master's qualification work of Valerii A. Nikolaichuk.

Topic of the work — «Automated cryptocurrency market analysis and trading decision-making system».

The aim of the master's qualification work is the development and study of an automated decision-support system for trading on the cryptocurrency market that combines methods of intelligent time-series analysis (gradient boosting, recurrent neural networks, Transformer) with a deep reinforcement learning model for adaptive position sizing, with the goal of achieving a statistically significant improvement of the Sharpe ratio compared with the passive Buy-and-Hold benchmark on historical BTC/USDT and ETH/USDT data.

Object of the study — the process of trading decision-making on the cryptocurrency market within decision-support systems based on intelligent data analysis methods.

Subject of the study — methods and algorithms of intelligent time-series analysis and reinforcement learning for automated generation of trading signals and portfolio management in a high-volatility, around-the-clock cryptocurrency market environment.

Scientific novelty of the work consists in the design of a hybrid decision-support architecture in which a discriminative price-direction forecast produced by machine learning models is integrated as part of the state of a Markov decision process for a deep reinforcement learning agent that produces continuous position-sizing actions; in the justified use of the public Crypto Fear and Greed composite index as an open and methodologically transparent source of market sentiment, replacing privately-held microblogging APIs that became paid in 2023; and in the adaptation of the walk-forward expanding-window validation methodology to the hourly cryptocurrency timeframe with realistic transaction-cost and slippage modelling.

The work investigates contemporary approaches to intelligent cryptocurrency market analysis. A feature-engineering pipeline of more than 50 features is developed (technical indicators, temporal cyclic features, realised volatility, sentiment indicators). Four model classes are implemented: classical baseline strategies (Buy-and-Hold, MA Crossover, RSI Mean Reversion, Bollinger Breakout); an XGBoost direction classifier; an LSTM network with additive attention pooling; an encoder-only Transformer for time-series; a PPO reinforcement-learning agent for position sizing on a custom gymnasium environment. A three-stage business deployment strategy is proposed.

The qualification work consists of an introduction, four chapters of the main part, conclusions and a list of references. The work contains tables, figures and appendices.

Keywords: machine learning, deep learning, intelligent data analysis, cryptocurrency market, Bitcoin, Ethereum, trading strategy, reinforcement learning, PPO, LSTM, Transformer, XGBoost, walk-forward validation, Sharpe ratio, decision support system, Fear and Greed Index.

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ ТА ТЕРМІНІВ

Програмний інтерфейс застосунку (далі — API, Application Programming Interface)

Закон зростаючого ринку (далі — ARIMA, AutoRegressive Integrated Moving Average)

Середній справжній діапазон (далі — ATR, Average True Range)

Площа під ROC-кривою (далі — AUC, Area Under ROC Curve)

Стратегія пасивного володіння (далі — B&H, Buy and Hold)

Бінарна перехресна ентропія (далі — BCE, Binary Cross-Entropy)

Смути Боллінджера (далі — BB, Bollinger Bands)

Складний річний темп зростання (далі — CAGR, Compound Annual Growth Rate)

Перехресна валідація (далі — CV, Cross-Validation)

Глибинне навчання (далі — DL, Deep Learning)

Глибока Q-мережа (далі — DQN, Deep Q-Network)

Експоненційне ковзне середнє (далі — EMA, Exponential Moving Average)

F1-міра — гармонічне середнє точності та повноти (далі — F1-score)

Crypto Fear and Greed Index — композитний індекс настроїв (далі — FNG)

Узагальнена оцінка переваги (далі — GAE, Generalized Advantage Estimation)

Регламент захисту даних ЄС (далі — GDPR, General Data Protection Regulation)

Графічний процесор (далі — GPU, Graphics Processing Unit)

Високочастотна торгівля (далі — HFT, High-Frequency Trading)

Бібліотека градієнтного бустінгу від Microsoft (далі — LightGBM)

Довга коротко-тривала пам'ять (далі — LSTM, Long Short-Term Memory)

Сходження ковзних середніх / розходження (далі — MACD, Moving Average Convergence/Divergence)

Максимальна просадка (далі — MaxDD, Maximum Drawdown)

Регламент ринків криптоактивів ЄС (далі — MiCA, Markets in Crypto-Assets Regulation)

Машинне навчання (далі — ML, Machine Learning)

Багатошаровий перцептрон (далі — MLP, Multi-Layer Perceptron)

Марковський процес прийняття рішень (далі — MDP, Markov Decision Process)

Свічковий ряд: відкриття, максимум, мінімум, закриття, обсяг (далі — OHLCV)

Передбачення на валідаційних фолдах (далі — OOF, Out-of-Fold)

Алгоритм проксимальної політики (далі — PPO, Proximal Policy Optimisation)

Друга платіжна директива ЄС (далі — PSD2, Payment Services Directive 2)

Навчання з підкріпленням (далі — RL, Reinforcement Learning)

Крива характеристик приймача (далі — ROC, Receiver Operating Characteristic)

Індекс відносної сили (далі — RSI, Relative Strength Index)

Просте ковзне середнє (далі — SMA, Simple Moving Average)

Система підтримки прийняття рішень (далі — СППР)

Часовий темпоральний Transformer (далі — TFT, Temporal Fusion Transformer)

Елементи матриці плутанини (далі — TP/FP/FN/TN, True/False Positive/Negative)

Універсальний координований час (далі — UTC, Coordinated Universal Time)

Підвищення градієнтного бустінгу (далі — XGBoost, eXtreme Gradient Boosting)

Walk-Forward валідація (далі — WFV)

Кваліфікаційна робота магістра (далі — KPM)

ПЕРЕЛІК ІЛЮСТРАЦІЙ

Рисунок 2.1. Шарувата архітектура автоматизованої СППР

Рисунок 2.2. Динаміка ціни BTC/USDT за досліджуваний період

Рисунок 2.3. Гістограма годинних логарифмічних дохідностей BTC і ETH

Рисунок 2.4. Динаміка індексу Crypto Fear and Greed за період

Рисунок 2.5. Кореляційна матриця ключових ознак

Рисунок 3.1. Криві накопиченого капіталу базових еталонних стратегій

Рисунок 3.2. Топ-20 найбільш важливих ознак XGBoost-класифікатора (gain)

Рисунок 3.3. Криві навчання LSTM та Transformer-моделей

Рисунок 3.4. Гістограма дій PPO-агента у тестовій вибірці

Рисунок 3.5. Криві накопиченого капіталу всіх моделей у єдиному масштабі

Рисунок 3.6. Часовий ряд просадки (drawdown) усіх моделей

Рисунок 4.1. Архітектура промислової реалізації автоматизованої СППР

ПЕРЕЛІК ТАБЛИЦЬ

Таблиця 1.1. Порівняння існуючих підходів до інтелектуальної торгівлі

Таблиця 2.1. Загальна характеристика наборів даних

Таблиця 3.1. Орієнтовні результати базових еталонних стратегій на BTC/USDT

Таблиця 3.2. Підсумкове порівняння моделей за портфельними метриками

ВСТУП

Актуальність теми дослідження.

Ринок криптовалют за останнє десятиліття зазнав стрімкої трансформації від нішевої експериментальної екосистеми до повноцінного класу фінансових активів із сукупною капіталізацією, що станом на початок 2026 року перевищує 2,5 трлн доларів США. Цілодобовий характер торгівлі, висока волатильність, фрагментована ліквідність між десятками централізованих та децентралізованих бірж, а також відсутність єдиного маркет-мейкера створюють унікальне середовище, у якому традиційні методи технічного й фундаментального аналізу, розроблені для централізованих фондових ринків, демонструють обмежену ефективність. У цих умовах автоматизовані системи підтримки прийняття торговельних рішень (СППР), що базуються на методах інтелектуального аналізу даних, стають ключовим інструментом отримання інформаційної переваги як для роздрібних інвесторів, так і для інституційних учасників ринку.

Сучасна архітектура таких систем еволюціонує у напрямку гібридних рішень, у яких поєднуються три якісно різні підсистеми: підсистема прогнозування цінової динаміки на основі глибоких нейронних мереж (LSTM, Transformer); підсистема врахування недетермінованих факторів через моделювання настроїв ринку (sentiment analysis); і підсистема прийняття безпосереднього торговельного рішення засобами навчання з підкріпленням (RL, reinforcement learning). Кожна з цих підсистем окремо є об'єктом активних досліджень, проте задача їх інтеграції у єдину виробничо орієнтовану архітектуру СППР, з урахуванням реалістичних транзакційних витрат, прослизання, концептуального дрейфу й нормативних обмежень, залишається відкритою науково-практичною проблемою. Наявні комерційні рішення (трейдингові боти класу 3Commas, Cryptohopper, HaasOnline) переважно реалізують детерміновані стратегії на базі правил із обмеженою адаптивністю,

тоді як академічні дослідження часто залишаються на рівні моделей-прототипів без врахування шару прийняття рішень та оцінки портфельних метрик.

Окремо актуальною залишається проблема методології оцінювання якості автоматизованих торгових стратегій. Безкритична переоцінка результатів класичних класифікаційних метрик (точність, F1-міра) не відображає реальної прибутковості, оскільки не враховує асиметрії транзакційних витрат, ефекту складних відсотків, послідовності помилок, що може призводити до формально високих, проте неприбуткових моделей. Перехід до набору портфельних метрик (Sharpe, Sortino, Calmar, MaxDD, CAGR) та використання walk-forward валідації замість K-fold є критично важливим для достовірного оцінювання, проте ці підходи не уніфіковані у літературі.

Розроблення комплексного програмного рішення, що системно поєднує методи інтелектуального аналізу даних, навчання з підкріпленням і коректну методологію оцінювання, є актуальним науково-прикладним завданням, що відповідає сучасним викликам цифрової економіки та потребам учасників криптовалютного ринку.

Зв'язок роботи з науковими програмами, планами, темами.

Кваліфікаційна робота магістра виконана на кафедрі технологій управління факультету інформаційних технологій Київського національного університету імені Тараса Шевченка в рамках наукового напрямку кафедри «Інтелектуальний аналіз даних та системи підтримки прийняття рішень».

Мета і завдання дослідження.

Метою кваліфікаційної роботи магістра є розробка та дослідження автоматизованої системи підтримки прийняття торговельних рішень на ринку криптовалют, що поєднує методи інтелектуального аналізу часових рядів (градієнтний бустінг, рекурентні нейронні мережі, Transformer) із моделлю глибокого навчання з підкріпленням для динамічного управління розміром

позиції, з обґрунтуванням ефективності засобами портфельних метрик у порівнянні з еталонною стратегією пасивного володіння.

Для досягнення поставленої мети необхідно вирішити такі завдання:

- 1) провести аналіз сучасних підходів до інтелектуального аналізу даних ринку криптовалют, систематизувати методи прогнозування цінової динаміки, аналізу настроїв та навчання з підкріпленням у застосуванні до задач алгоритмічної торгівлі;
- 2) розробити уніфіковану схему збору, обробки та зберігання історичних даних ринку криптовалют, інтегровану з композитним sentiment-індикатором; здійснити розвідувальний аналіз даних та виявити статистичні закономірності, релевантні для подальшого моделювання;
- 3) розробити систему конструювання ознак (feature engineering), що включає технічні індикатори, темпоральні циклічні фічі, метрики реалізованої волатильності та sentiment-фічі;
- 4) реалізувати методологію walk-forward валідації з expanding window та обґрунтувати її доцільність як методу запобігання look-ahead bias і витоку даних у задачах із часовими рядами;
- 5) реалізувати та порівняти дискримінативні моделі прогнозування напрямку руху ціни на основі XGBoost, LSTM з механізмом уваги та encoder-only Transformer;
- 6) сформулювати задачу управління торговою позицією як марковський процес прийняття рішень (MDP) і реалізувати агента глибокого навчання з підкріпленням на основі алгоритму PPO у власному середовищі gymnasium;
- 7) розробити векторизований бектест-двигун із реалістичним моделюванням транзакційних витрат і прослизання та провести експериментальне порівняння всіх моделей у єдиній методологічній рамці;
- 8) розробити стратегію впровадження запропонованої СППР у промислове середовище, що враховує управління ризиками, моніторинг concept drift та

юридично-етичні аспекти регулювання обігу криптовалют у
Європейському Союзі та Україні.

Об'єкт дослідження.

Об'єктом дослідження є процес автоматизованого аналізу ринку криптовалют і прийняття торговельних рішень у системах підтримки прийняття рішень.

Предмет дослідження.

Предметом дослідження є методи, моделі та алгоритми інтелектуального аналізу часових рядів і навчання з підкріпленням для автоматизованого формування торгових сигналів та динамічного управління торговою позицією на ринку криптовалют в умовах високої волатильності та цілодобової торгівлі.

Методи дослідження.

У роботі використано такий комплекс методів: методи статистичного та розвідувального аналізу часових рядів; методи машинного навчання, у тому числі градієнтний бустінг (XGBoost) та логістична регресія; методи глибинного навчання — рекурентні нейронні мережі LSTM з механізмом адитивної уваги, архітектура Transformer-енкодера з позиційним кодуванням; методи навчання з підкріпленням, зокрема алгоритм PPO у формулюванні марковського процесу прийняття рішень; методи валідації моделей — walk-forward з expanding window, out-of-fold (OOF) передбачення; методи оцінки інвестиційних стратегій — коефіцієнти Шарпа, Сортіно, Кальмара, аналіз максимальної просадки (MaxDD), складний річний темп зростання (CAGR), Profit Factor, Win Rate.

Наукова новизна одержаних результатів.

Наукова новизна полягає у наступному:

- 1) запропоновано та обґрунтовано гібридну архітектуру СППР, у якій дискримінативний прогноз напрямку руху ціни моделями машинного навчання слугує елементом стану марковського процесу прийняття рішень для агента глибокого навчання з підкріпленням, що формує безперервне рішення про розмір позиції. На відміну від поширеного підходу, у якому один моноліт-агент приймає рішення з «сирого» простору ознак,

запропонована декомпозиція дозволяє відокремити задачу прогнозування від задачі управління ризиком та незалежно оптимізувати кожну з них;

- 2) удосконалено методологію конструювання ознак для криптовалютного ринку шляхом включення композитного індексу Crypto Fear and Greed як публічно доступного, методологічно прозорого джерела sentiment-сигналу, що уможливорює відтворюваність експериментів на відміну від приватних мікроблогінгових джерел, які з 2023 року є переважно платними;
- 3) адаптовано методологію walk-forward валідації з expanding window до годинного таймфрейму криптовалютного ринку з урахуванням реалістичних транзакційних витрат (0,1% taker-комісія Binance) та прослизання (0,05% на угоду), запропоновано уніфіковану рамку оцінки моделей за набором портфельних метрик у порівнянні з еталонною стратегією B&H.

Практичне значення одержаних результатів.

Розроблено повнофункціональний прототип автоматизованої системи СППР на мові програмування Python з відкритим вихідним кодом. Прототип включає підсистеми завантаження даних, конструювання ознак, тренування та оцінки моделей машинного й глибокого навчання, агента глибокого навчання з підкріпленням, векторизований бектест-двигун, інтерактивний інформаційний інтерфейс на основі Streamlit. Запропонована трирівнева стратегія впровадження дозволяє поетапно інтегрувати систему у промислове середовище: від режиму інформаційно-консультативної підтримки трейдера до напівавтоматичного режиму з підтвердженням операцій оператором та повністю автоматичного режиму з контролем ризиків.

Апробація результатів.

Результати роботи апробовано на історичних даних пар BTC/USDT та ETH/USDT біржі Binance за період орієнтовно 3 років з використанням реалістичної моделі транзакційних витрат і прослизання. Прототип системи

розгорнуто у вигляді локального застосунку на основі Streamlit; вихідний код та технічна документація доступні у вигляді репозиторію проєкту.

Структура та обсяг роботи.

Кваліфікаційна робота магістра складається зі вступу, чотирьох розділів, висновків, списку використаних джерел та додатків. Загальний обсяг роботи — близько 50 сторінок основного тексту. Робота містить рисунки, таблиці, формули та додатки з програмним кодом ключових компонентів системи.

РОЗДІЛ 1. ТЕОРЕТИЧНІ ЗАСАДИ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ РИНКУ КРИПТОВАЛЮТ І ПРИЙНЯТТЯ ТОРГОВЕЛЬНИХ РІШЕНЬ

1.1. Особливості ринку криптовалют як об'єкта алгоритмічного аналізу

Ринок криптовалют, започаткований публікацією Сатоші Накамото [41], за останні 17 років трансформувався з вузької технологічної експериментальної ніші на повноцінний клас фінансових активів із капіталізацією понад 2 трлн USD. Він посідає особливе місце у структурі сучасних фінансових ринків і характеризується низкою унікальних рис, що мають принципове значення для проєктування автоматизованих систем аналізу та прийняття торговельних рішень. На відміну від традиційних регульованих фондових та валютних ринків, що функціонують протягом фіксованих торгових сесій з єдиним маркет-мейкером або консорціумом таких, ринок криптовалют функціонує цілодобово, без вихідних та технологічних перерв; ліквідність є фрагментованою між сотнями централізованих (CEX, Centralized Exchange) і децентралізованих (DEX, Decentralized Exchange) бірж; цінова динаміка формується сукупною дією роздрібних учасників, маркет-мейкерів-маркет-тейкерів, арбітражних ботів і власне smart-контрактів автоматизованих маркет-мейкерів (AMM). Цілодобовий характер торгівлі усуває природну сегментацію часових рядів за торговими сесіями і вимагає переосмислення темпоральних фіч (час доби, день тижня) як таких, що мають циклічну, а не сегментну природу.

Висока волатильність є наступною характерною рисою криптовалютного ринку, що відрізняє його від інших класів активів. Денна волатильність основних пар (BTC/USDT, ETH/USDT) у середньому в 3–5 разів перевищує волатильність провідних фондових індексів (S&P 500, NASDAQ Composite) і у 8–12 разів — основних валютних пар (EUR/USD, GBP/USD). Цей факт має подвійний наслідок: з одного боку, він збільшує потенційну прибутковість стратегій, що коректно прогнозують рухи; з іншого — підвищує ризик catastrophic loss за рахунок раптових різких рухів («чорних лебедів»), таких як

обвал 12 березня 2020 року, події FTX листопада 2022, обвал стейблкоїна Terra/Luna травня 2022. Будь-яка СППР для криптовалютного ринку має передбачати механізми захисту капіталу від подібних подій (стоп-лосси, ліміти позицій, динамічний sizing).

Третя структурна особливість — фрагментація ліквідності та цінова неоднорідність. Один і той самий торговий інструмент (наприклад, BTC/USDT) одночасно котирується на десятках бірж, причому ціни можуть розходитися на десятки і сотні базисних пунктів, а в окремих випадках — на одиниці відсотків. Ця фрагментація створює можливості для арбітражних стратегій, але одночасно ускладнює бектестування: одна й та сама стратегія, протестована на даних різних бірж, може демонструвати суттєво різні результати. У цій роботі як основне джерело даних обрано Binance — найбільшу за обсягом торгів централізовану біржу станом на 2026 рік, що забезпечує максимальну стабільність ліквідності та коректність припущень про можливість виконання модельованих угод.

Четверта особливість — неоднорідність учасників та домінування алгоритмічної торгівлі. За оцінками дослідницьких компаній (Kaiko, Glassnode), частка алгоритмічних учасників на спотовому ринку основних пар перевищує 70%, а на ринку безстрокових ф'ючерсів сягає 90%. Це означає, що швидкість реакції на нову інформацію є критично високою, а традиційні стратегії, побудовані на низькочастотних сигналах, мають істотну конкуренцію з боку маркет-мейкерських стратегій з низькою латентністю. Для автоматизованих СППР, що працюють на годинному та денному таймфреймах, це означає необхідність орієнтації не на пошук арбітражних можливостей у мікроструктурі, а на ідентифікацію більш повільних патернів — режимів ринку, циклів настроїв, on-chain метрик активності мережі.

П'ята особливість — наявність унікального для криптовалютного ринку класу даних — on-chain метрик. Оскільки переважна більшість блокчейнів є публічними, дослідник має доступ до повної історії транзакцій, балансів адрес, активності майнерів, потоків коштів між біржами та холодними гаманцями. Це

породжує специфічні фічі, такі як NVT (Network Value to Transactions), MVRV (Market Value to Realized Value), частка прибуткових адрес (Percent of Supply in Profit), потоки на біржі (Exchange Inflow/Outflow). У цій роботі on-chain аналіз винесено за рамки експериментальної частини через обмеження часу та обсягу, проте методологія залишає простір для його інтеграції на наступних етапах розвитку системи.

1.2. Підходи до аналізу криптовалютного ринку

Сучасна практика аналізу криптовалютного ринку традиційно поділяється на три великі парадигми, кожна з яких спирається на власну теоретичну базу та арсенал інструментів: технічний аналіз, фундаментальний аналіз і аналіз настроїв.

Технічний аналіз бере свій початок у роботах Чарльза Доу кінця XIX століття та фокусується на вивченні цінової динаміки та обсягів торгів як самодостатніх джерел інформації. Базова гіпотеза технічного аналізу — слабка форма гіпотези ефективного ринку у формулюванні Юджина Фама [1], згідно з якою вся доступна історична інформація про ціни вже відображена у поточній ціні, проте структурні патерни (тренди, повернення до середнього, рівні підтримки/опору) повторюються через типову поведінку учасників. Інструментарій технічного аналізу складається з двох основних груп: графічних патернів (трикутники, голова-плечі, прапорці) та технічних індикаторів — алгебраїчних перетворень цінового ряду. У цій роботі застосовано класичні індикатори: ковзні середні (SMA, EMA), осцилятор RSI Велса Уайлдера, конвергенція ковзних середніх MACD Джеральда Апеля, смуги Боллінджера, середній справжній діапазон ATR, індекс спрямованого руху ADX, балансовий обсяг OBV. Ці індикатори обрані не як єдиний фінальний прогностичний інструмент, а як вхідні фічі для моделей машинного навчання, що дозволяє системі автоматично визначати їх відносну вагу для конкретного режиму ринку.

Фундаментальний аналіз криптовалютного ринку, на відміну від фондового, не має чітко визначеного аналога фінансової звітності емітента. Його реалізація спирається на технологічні характеристики мережі, рівень розгортання інфраструктури (кількість вузлів, активних адрес, обсяг хешрейту), регуляторне середовище та макроекономічний контекст. У роботі Чена та інших [2] показано, що частка фундаментальних факторів у короткостроковій (до 24 годин) ціновій динаміці є мінімальною, проте на горизонтах від місяця і вище — переважаючою. Оскільки досліджувана СППР орієнтована на годинний таймфрейм, фундаментальний аналіз винесено поза рамки моделювання, але залишено як концептуальний шар у архітектурі системи (рисунок 2.1 у Розділі 2).

Аналіз настроїв (sentiment analysis) — третя і відносно молода парадигма, що формується на стику класичного аналізу часових рядів та обробки природної мови. Його суть полягає у вилученні агрегованої характеристики «настрою» ринку з неструктурованих джерел — публікацій у соціальних мережах (Twitter/X, Reddit, Telegram), новинних агрегаторів, голосувань спільноти. У ранніх роботах [3, 4] було показано наявність значущої кореляції між агрегованими sentiment-метриками й короткостроковою динамікою цін окремих криптоактивів, причому з характерною часовою затримкою у 1–4 години, що теоретично уможливлює побудову прибуткових стратегій. У наступних дослідженнях було розроблено спеціалізовані мовні моделі для крипторинку — CryptoBERT, FinBERT Арачі [58] — натреновані на великих корпусах фінансових текстів. Проте з 2023 року доступ до Twitter API для академічних досліджень став практично неможливим через перехід платформи на платну модель з мінімальними планами понад 200 доларів США на місяць, що робить відтворюваність експериментів на цьому джерелі проблематичною. У цій роботі як ключове джерело sentiment-сигналу обрано композитний індекс Crypto Fear and Greed Index сервісу [alternative.me](https://alternative.me/crypto/fear-greed/) — публічно доступне, методологічно прозоре джерело з відкритою історією з 2018 року.

1.3. Методи інтелектуального аналізу часових рядів у фінансових застосуваннях

Задача прогнозування фінансових часових рядів у формальному сенсі є однією з найбільш досліджуваних проблем кількісних фінансів та машинного навчання. Її формалізація має такий вигляд: задано часовий ряд $\{x_1, x_2, \dots, x_T\}$ із значеннями ціни активу та супутніх характеристик; необхідно побудувати функцію $\hat{f}: R^{F \times W} \rightarrow R$ або $\hat{f}: R^{F \times W} \rightarrow \{0,1\}$, що за вікном довжини W та F ознаками передбачає майбутню дохідність або напрямок руху на горизонті H . Еволюція підходів до розв'язання цієї задачі може бути представлена у вигляді трьох поколінь: класичні статистичні моделі, класичне машинне навчання, глибоке навчання.

Класичні статистичні моделі — найдавніший клас, представлений насамперед сімейством ARIMA (AutoRegressive Integrated Moving Average) Бокса—Дженкінса. Модель ARIMA(p, d, q) передбачає, що значення ряду після d -разового диференціювання є лінійною комбінацією p попередніх значень та q попередніх помилок:

$$y'_t = c + \sum_{i=1}^p \phi_i y'_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t \quad (1.1)$$

Перевагою ARIMA є інтерпретованість і теоретична обґрунтованість; недоліком — припущення про лінійність, стаціонарність та одновимірність ряду. Розширення (ARIMAX, VARMA, GARCH) частково знімають ці обмеження, проте при роботі з багатовимірними нелінійними даними криптовалютного ринку точність прогнозу на основі сімейства ARIMA рідко перевищує точність простих наївних бенчмарків (random walk, поточна ціна як прогноз) [5, 59]. Класичні моделі умовної гетероскедастичності GARCH Боллерслева [45] дозволяють краще моделювати кластерізацію волатильності, проте їх застосування у задачах прогнозу напрямку руху ціни є обмеженим.

Методи класичного машинного навчання — другий рівень еволюції, що включає алгоритми, здатні моделювати нелінійні залежності у

багатовимірному просторі ознак. Найбільш ефективним для табличних даних на цей час залишається градієнтний бустінг над деревами рішень (XGBoost, LightGBM, CatBoost). Методологія градієнтного бустінгу, формалізована Фрідманом [6], будує ансамбль слабких моделей h_m ітеративно, де кожна нова модель навчається мінімізувати залишок попереднього ансамблю:

$$F_m(x) = F_{m-1}(x) + \nu \cdot h_m(x), \quad h_m = \underset{h}{\operatorname{argmin}} \sum_i L(y_i, F_{m-1}(x_i) + h(x_i)) \quad (1.2)$$

де $\nu \in (0,1]$ — швидкість навчання (shrinkage). XGBoost (eXtreme Gradient Boosting) Чена та Гестріна [7] суттєво розширив базову схему регуляризацією на основі другого порядку розкладу функції втрат у ряд Тейлора, ефективною паралельною побудовою дерев та підтримкою розрідженості. Емпірично XGBoost залишається state-of-the-art для табличних задач середнього розміру (до десятків мільйонів рядків) та надає надзвичайно цінну інтерпретованість через важливість ознак (feature importance) і SHAP-значення, що критично для системи СППР з вимогами пояснення рішень.

Глибинне навчання — третій і найновіший клас методів. Його застосування до фінансових часових рядів обґрунтовується здатністю автоматично виділяти ієрархічні представлення без необхідності ручного конструювання фіч. Основними архітектурами, релевантними для задачі, є:

Рекурентні нейронні мережі — клас моделей, що містять зворотні зв'язки у вхідному графі обчислень і дозволяють обробляти послідовності змінної довжини. Архітектура LSTM (Long Short-Term Memory), запропонована Хохрайтером і Шмідхубером [8], розв'язує проблему згасання градієнтів у класичних RNN через введення трьох вентилів: вхідного, вихідного та вентиля забування. У формальному вигляді робота однієї LSTM-комірки описується системою рівнянь:

$$\begin{aligned}
f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad \tilde{C}_t \\
&= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \odot o_t \\
&= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad h_t = o_t \odot \tanh(C_t) \quad (1.3)
\end{aligned}$$

Вентиль забування f_t керує тим, яку частку попереднього стану клітини C_{t-1} зберегти; вхідний вентиль i_t — наскільки врахувати нову інформацію; вихідний вентиль o_t формує нове приховане представлення h_t . Така архітектура здатна моделювати довготривалі залежності, а також забезпечує стабільність градієнта при зворотному поширенні, що було серйозною проблемою класичних RNN.

Архітектура Transformer, запропонована Васвані та співавторами [9] для задач машинного перекладу, базується на механізмі множинної самоуваги (multi-head self-attention), що дозволяє кожній позиції послідовності безпосередньо звертатись до всіх інших позицій без послідовної рекурентної обробки. Базовий механізм уваги визначається формулою:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1.4)$$

де Q, K, V — матриці запитів, ключів і значень, отримані лінійним перетворенням вхідного представлення. У множинній самоувазі обчислюється h паралельних головок уваги, результати яких конкатенуються та проєктуються у вихідний простір. Завдяки відсутності рекурентності Transformer демонструє кращу масштабованість на GPU та краще моделює довготривалі залежності, проте потребує позиційного кодування (positional encoding) для збереження інформації про порядок послідовності. Адаптації Transformer для часових рядів — Informer [10], Autoformer [11], Temporal Fusion Transformer (TFT) [12] — активно досліджуються; у даній роботі застосовано спрощений encoder-only варіант з синусоїдальним позиційним кодуванням як прийнятний компроміс між якістю прогнозу та обчислювальною складністю навчання.

1.4. Навчання з підкріпленням у задачах алгоритмічної торгівлі

Концептуально торгівля на фінансовому ринку є послідовним процесом прийняття рішень в умовах часткової спостережуваності, стохастичності та затримки винагороди — тобто природно вкладається у формалізм навчання з підкріпленням (RL, Reinforcement Learning). Класичним формальним описом такої задачі є марковський процес прийняття рішень (MDP, Markov Decision Process), що задається кортежем (S, A, P, R, γ) , де S — простір станів, A — простір дій, $P(s'|s, a)$ — функція переходу, $R(s, a)$ — функція винагороди, $\gamma \in [0, 1)$ — коефіцієнт дисконтування. Метою агента є знаходження політики $\pi^*: S \rightarrow A$, що максимізує очікувану дисконтовану кумулятивну винагороду:

$$\pi^* = \underset{\pi}{argmax} E_{\pi} \left[\sum_{t=0}^{\infty} \gamma^t R(s_t, a_t) \right] \quad (1.5)$$

У контексті торгової задачі простір станів складається з вектора фіч ринку у поточний момент часу та внутрішнього стану агента (поточна позиція, нереалізований PnL, drawdown); простір дій — з цільової позиції на наступний бар (бінарної у випадку discrete actions або безперервної у випадку box action space); функція винагороди — з зміни вартості портфеля з вирахуванням транзакційних витрат і штрафу за просадку.

Існує дві основні сімейства алгоритмів RL, придатних для розв'язання такої задачі: value-based та policy-based. Value-based алгоритми, такі як Q-learning та його глибока версія DQN [13], навчаються оцінювати очікувану корисність кожної пари (стан, дія) і обирати дію з найвищою оцінкою. Їх перевага — простота, теоретична обґрунтованість збіжності у певних умовах; недолік — обмеженість дискретним простором дій та нестабільність на нестационарних задачах. Policy-based алгоритми безпосередньо параметризують політику $\pi_{\theta}(a|s)$ і оптимізують її методом градієнтного спуску за теоремою про градієнт політики. Найбільш поширеним сучасним алгоритмом цього сімейства є PPO (Proximal Policy Optimisation) Шульмана та співавторів [14], що поєднує переваги стабільності trust-region методів з обчислювальною

простотою стандартного градієнта політики через введення обрізаної цільової функції:

$$L^{CLIP}(\theta) = \hat{E}_t[\min(r_t(\theta)\hat{A}_t, \text{clip}(r_t(\theta), 1 - \epsilon, 1 + \epsilon)\hat{A}_t)] \quad (1.6)$$

де $r_t(\theta) = \pi_\theta(a_t|s_t)/\pi_{\theta_{old}}(a_t|s_t)$ — відношення ймовірностей нової та попередньої політик, $\hat{A}_t$ — оцінка функції переваги (advantage), ϵ — параметр обрізання (зазвичай 0,2). Обрізання запобігає надмірно великим оновленням, що могли б дестабілізувати навчання, і робить PPO одним з найбільш практично надійних алгоритмів RL для застосування у складних реальних задачах. У даній роботі саме PPO обрано як алгоритм для агента управління позицією. Альтернативними сучасними алгоритмами безперервного контролю є Soft Actor-Critic Хаарноя та співавторів [50] і Twin Delayed DDPG Фуджімото та співавторів [51], які формують напрямки подальшого розвитку запропонованої системи.

Окремо зазначимо клас гібридних архітектур, у яких прогнозна підсистема навчається окремо як supervised-задача (передбачення напрямку чи дохідності), а її вихід подається у простір станів RL-агента. Така декомпозиція має кілька переваг: спрощує процес дебагу за рахунок ізоляції підсистем; дозволяє використовувати багатий арсенал supervised-методів; відокремлює задачу прогнозування (стаціонарну на коротких горизонтах) від задачі управління ризиком (стохастичної). Саме такий підхід реалізовано у запропонованій СППР та представлено як основний елемент наукової новизни роботи.

Для систематизації місця даного дослідження у наявному науковому ландшафті у таблиці 1.1 наведено стисле порівняння кількох ключових робіт, що використовують методи навчання з підкріпленням для задач алгоритмічної торгівлі.

Таблиця 1.1. Порівняння існуючих підходів до інтелектуальної торгівлі засобами навчання з підкріпленням

Робота	Акти	Архітектур	Метрика,
ви	а	період	
Jiang та ін. [28]	Топ-12 криптовалют ют	Direct Portfolio Management + CNN	APV $\approx$ 4,5 за 50 діб
Théate, Ernst [29]	30 акцій DJIA	TDQN (Trading Deep Q-Network)	Sharpe $\approx$ 1,6 за 2010–2020
FinRL Liu та ін. (2020) [30]	Портфель акцій DJI	Бібліотека PPO/A2C/DDPG	Sharpe $\approx$ 1,3 за 2009–2020
Théate, Ernst [29]	Криптовари (огляд)	DQN з reward shaping	Sharpe $\approx$ 1,4 за 2018–2020
Це дослідження	BTC /USDT, ETH/USD	Гібрид XGBoost+LSTM +Transformer+P	Sharpe 2,18 $\pm$ 0,32 за 2023–2026
Т	PO		

На відміну від наявних робіт, запропонована система: (1) застосовує строгу декомпозицію на дискримінативний прогноз і RL-агент з прогнозом у складі стану MDP; (2) інтегрує публічно доступний sentiment-сигнал замість приватних мікроблогінгових джерел; (3) застосовує walk-forward з expanding window замість стандартного train/test поділу.

1.5. Аналіз настроїв ринку та індекс Crypto Fear and Greed

Sentiment analysis у застосуванні до криптовалютного ринку розвивається у двох напрямках: побудова фічі настроїв з мікроблогінгових та новинних джерел (Twitter/X, Reddit, новинні агрегатори) із застосуванням мовних моделей; використання композитних агрегованих індексів, що публікуються

спеціалізованими сервісами. Перший напрямок має теоретичну перевагу у вигляді більшої граничної інформативності, проте на практиці зіткнувся з низкою проблем: монетизацією Twitter API (вартість мінімального тарифного плану для академічних досліджень з 2023 року перевищує 200 USD/міс); змінністю структури джерел; необхідністю фільтрування спаму та координованих маніпуляційних кампаній; високою обчислювальною вартістю інференсу мовних моделей (FinBERT, CryptoBERT) на великих обсягах історичних даних.

Другий напрямок — використання композитних індексів — позбавлений цих недоліків. Найвідомішим представником є Crypto Fear and Greed Index (FNG) сервісу alternative.me, що публікується щодоби з 2018 року. Індекс представлений значенням від 0 (extreme fear) до 100 (extreme greed) і обчислюється як зважене середнє п'яти компонент:

- 1) волатильність (25%) — порівняння поточної 30-денної волатильності BTC з річним середнім; підвищена волатильність трактується як страх;
- 2) ринковий момент і обсяг (25%) — порівняння поточного 30/90-денного руху ціни та обсягу з історичною нормою;
- 3) активність у соціальних мережах (15%) — кількість і темп зростання згадок Bitcoin у Twitter/X;
- 4) опитування (15%) — щотижневі опитування інвесторів (на час підготовки роботи компонент часто має нульову вагу);
- 5) домінування Bitcoin (10%) — чим більша частка BTC у загальній капіталізації, тим менший ризик-апетит;
- 6) пошукові запити (10%) — об'єм пошукових запитів за криптовалютами у Google Trends.

Емпіричні дослідження [15, 16] підтверджують наявність статистично значущого зв'язку між значенням FNG та подальшою динамікою цін, особливо на горизонтах від декількох діб і у режимах екстремальних значень ($FNG < 20$ або $FNG > 80$). У задачі, що розглядається, значення FNG використовується як

одна з ознак простору ознак моделей машинного навчання та як компонент стану RL-агента. Денна частота даних інтерполюється на годинний таймфрейм методом forward-fill, що не призводить до витоку інформації, оскільки опубліковане значення індексу за день D доступне на момент відкриття будь-якої свічки дня D .

1.6. Метрики оцінки якості торгових стратегій

Коректний вибір метрик оцінки автоматизованої торгової стратегії має ключове значення для адекватної інтерпретації результатів і прийняття інженерних рішень. Поширеною помилкою у дослідницькій літературі є оцінка моделей лише за класифікаційними метриками (точність, F1-міра, ROC-AUC) на задачі прогнозування напрямку руху, без подальшого моделювання портфеля. Така практика не враховує асиметрії транзакційних витрат, ефекту складних відсотків та послідовності помилок: модель з 55% точністю, що періодично припускається серій з 10 помилок поспіль, може у результаті бути збитковою, тоді як модель з 52% точністю та рівномірним розподілом помилок — прибутковою. Тому необхідно поряд з класифікаційними метриками застосовувати набір портфельних показників.

Складний річний темп зростання (CAGR, Compound Annual Growth Rate) — базова метрика прибутковості, що відображає геометричне середнє річної дохідності:

$$CAGR = \left(\frac{V_T}{V_0} \right)^{1/n} - 1 \quad (1.7)$$

де V_0 і V_T — початкова й кінцева вартість портфеля, n — кількість років.

Коефіцієнт Шарпа (Sharpe Ratio), запропонований Вільямом Шарпом [17], — найвідоміша метрика співвідношення прибутку та ризику:

$$Sharpe = \frac{E[R - R_f]}{\sigma(R - R_f)} \cdot \sqrt{N} \quad (1.8)$$

де R — серія періодних дохідностей, R_f — безризикова ставка, N — кількість періодів у році (для годинних даних $N = 8760$). Інтерпретація:

коефіцієнт Шарпа понад 1 вважається доброю стратегією, понад 2 — дуже доброю, понад 3 — винятковою.

Коефіцієнт Сортино (Sortino Ratio) — модифікація коефіцієнта Шарпа, що враховує лише downside-волатильність:

$$Sortino = \frac{E[R - R_f]}{\sigma_{down}(R - R_f)} \cdot \sqrt{N} \quad (1.9)$$

де σ_{down} — стандартне відхилення лише негативних дохідностей. Сортино є більш відповідним показником для задач, де упередження проти позитивних відхилень є небажаним (наприклад, у трейдингу зростання волатильності у вигоду — це не ризик, а можливість).

Максимальна просадка (MaxDD, Maximum Drawdown) — найбільше відносне падіння капіталу від попереднього історичного максимуму:

$$MaxDD = \min_t \left(\frac{V_t - \max_{s \leq t} V_s}{\max_{s \leq t} V_s} \right) \quad (1.10)$$

MaxDD є ключовим практичним показником, що відображає психологічну та регуляторну стійкість стратегії: у переважній більшості інституційних мандатів стратегії з MaxDD понад 30% не допускаються до експлуатації.

Коефіцієнт Кальмара (Calmar Ratio) — комплексна метрика, що поєднує прибутковість і просадку:

$$Calmar = \frac{CAGR}{|MaxDD|} \quad (1.11)$$

Інтерпретація: значення понад 1 означає, що річна дохідність перевищує максимальну історичну просадку, що є практично важливим орієнтиром.

Profit Factor — відношення суми прибуткових до суми збиткових періодів:

$$PF = \frac{\sum_t \max(R_t, 0)}{\sum_t \max(-R_t, 0)} \quad (1.12)$$

Значення Profit Factor > 1 означає, що сумарний прибуток перевищує сумарний збиток. Для надійних стратегій бажано Profit Factor > 1,5.

Win Rate — частка прибуткових угод (або періодів) у загальній кількості. Самостійно ця метрика мало інформативна (наприклад, стратегія з Win Rate 90%, але середнім збитком у 10 разів більшим за середній прибуток, є збитковою), проте у поєднанні з Profit Factor та середнім розміром угоди дає повну картину.

У даній роботі усі моделі оцінюються за повним набором перелічених метрик, причому як головну індикативну метрику обрано коефіцієнт Шарпа, як головну метрику ризику — MaxDD, а як практично орієнтований показник — Calmar.

1.7. Методологія бектестингу: запобігання витоку даних і look-ahead bias

Бектестинг — процес моделювання торгової стратегії на історичних даних — є ключовим інструментом валідації, проте містить численні методологічні пастки, які можуть призвести до катастрофічного перевищення оцінки реальної ефективності стратегії. У роботі Лопеса де Прадо [18] систематизовано близько десятка типових помилок, з яких найбільш критичними для задачі цього дослідження є наступні три.

Look-ahead bias — використання при формуванні сигналу інформації, що недоступна у момент прийняття рішення. Класичний приклад — обчислення нормуючих статистик (середнє, стандартне відхилення) на повному наборі даних, включно з тестовою вибіркою. У цій роботі усі нормалізатори (RobustScaler) фітуються виключно на тренувальній вибірці; усі ковзні статистики обчислюються з виключенням поточного бару (через зсув `.shift(1)` на етапі формування фіч); цільова змінна формується як зсунута уперед дохідність, після чого всі рядки з NaN відкидаються.

Data leakage через перехресну валідацію K-fold — поширена помилка застосування стандартних методів CV до часових рядів. У K-fold кожен фолд містить випадково перемішані рядки, тому модель навчається на «майбутніх» даних і прогнозує «минулі», що не відповідає реальному сценарію розгортання. Коректним методом для часових рядів є walk-forward валідація з expanding або

rolling window: на кожній ітерації модель навчається на префіксі ряду, валідується на наступному відрізку, тестується на ще наступному, після чого вікно зсувається. У цій роботі застосовано схему expanding window з розмірами: $\text{train} \geq 1$ рік, $\text{validation} = 1$ місяць, $\text{test} = 1$ місяць, крок зсуву = 1 місяць.

Survivorship bias і вижила-вибірка активів — менш релевантний для одиничних активів, як у цій роботі (BTC, ETH є найстарішими і найліквіднішими криптовалютами), проте критичний при дослідженні мульти-активних портфелів. У роботі цей аспект задокументовано як обмеження поточної постановки.

Окремою важливою деталлю є **моделювання транзакційних витрат і прослизання**. Для криптовалютного ринку Binance taker fee для VIP-0 рівня становить 0,1% від обороту (у разі сплати у токени BNB — 0,075%); прослизання залежить від глибини ордербука та обсягу угоди. У цій роботі прийнято консервативну оцінку: фіксовані 0,1% taker fee + 0,05% slippage на одиничну операцію зміни позиції. Ця оцінка відповідає реалістичному сценарію роздрібного учасника з обсягом одиничної угоди до 100 000 USD на парах з найвищою ліквідністю. Для інституційного учасника з обсягом 1+ M USD за угоду модель вимагала б більш складного моделювання прослизання як функції обсягу, що залишається поза рамками поточної роботи.

Висновки до розділу 1

У першому розділі здійснено систематизацію теоретичних засад інтелектуального аналізу ринку криптовалют і прийняття торговельних рішень. Основні висновки розділу полягають у наступному:

1. Ринок криптовалют як об'єкт алгоритмічного аналізу має п'ять структурних особливостей, що принципово відрізняють його від традиційних фондових ринків: цілодобовий характер торгівлі; підвищена волатильність; фрагментована ліквідність між сотнями бірж; домінування алгоритмічних учасників; наявність унікального класу on-chain метрик. Ці особливості формують специфічні вимоги до архітектури СППР, зокрема

до робастності щодо різких рухів, до коректної обробки циклічних темпоральних фіч, до вибору джерел даних.

2. Сучасна практика аналізу криптовалютного ринку поєднує три парадигми — технічний аналіз, фундаментальний аналіз, аналіз настроїв, — кожна з яких має визначений діапазон ефективності залежно від часового горизонту. На годинному таймфреймі основним джерелом сигналу є технічні індикатори та sentiment-фічі, тоді як фундаментальний аналіз більш релевантний на горизонтах від місяця.
3. Еволюція методів інтелектуального аналізу часових рядів пройшла три покоління: класичні статистичні моделі (ARIMA), класичне машинне навчання (градієнтний бустінг), глибинне навчання (LSTM, Transformer). Кожне покоління привнесло принципово нові можливості: нелінійність (ML), автоматичне виділення ієрархічних представлень (DL), безпосереднє моделювання довготривалих залежностей через механізм уваги (Transformer).
4. Навчання з підкріпленням є природним формалізмом для задачі прийняття торгових рішень, формалізованої як марковський процес. Сучасний практично надійний алгоритм PPO забезпечує стабільність навчання за рахунок обрізаної цільової функції і був обраний як основа для агента управління позицією у розроблюваній СППР.
5. Композитний індекс Crypto Fear and Greed Index є методологічно прозорим, відтворюваним публічним джерелом sentiment-сигналу, що становить альтернативу приватним мікроблогінговим джерелам, доступ до яких з 2023 року обмежений монетизацією API.
6. Коректне оцінювання якості торгової стратегії потребує застосування набору портфельних метрик (Sharpe, Sortino, Calmar, MaxDD, CAGR, Profit Factor), а не лише класифікаційних метрик прогнозу напрямку. Як ключову метрику обрано коефіцієнт Шарпа.
7. Запобігання витоку даних і look-ahead bias є критично важливим у задачах часових рядів, що обумовлює використання walk-forward валідації з

expanding window замість стандартного K-fold та коректне моделювання транзакційних витрат і прослизання у бектесті.

РОЗДІЛ 2. ДАНІ ТА МЕТОДОЛОГІЯ ДОСЛІДЖЕННЯ

2.1. Джерела даних і протокол їх отримання

Експериментальне дослідження автоматизованої системи СППР проводилося на двох джерелах даних: ринкові дані (історичні годинні свічки) централізованої біржі Binance та композитний індекс настроїв Crypto Fear and Greed Index сервісу alternative.me. Вибір джерел обґрунтовується їх публічною доступністю без необхідності платної підписки, відкритістю історії, високою якістю та стабільністю інтерфейсу, можливістю відтворення експерименту незалежними дослідниками.

Ринкові дані Binance. Використано публічний REST API біржі (<https://api.binance.com/api/v3/klines>), що повертає історичні свічки (klines) для довільної торгової пари, з вибраним інтервалом (1 хв, 5 хв, 15 хв, 1 год, 4 год, 1 доба). Авторизація для отримання історичних даних не потрібна; ліміт запитів — 1200 на хвилину з однієї IP-адреси, що з суттєвим запасом перекриває потреби пакетного завантаження тривалих часових рядів. Для кожної свічки повертається кортеж із 12 значень: час відкриття (мс UTC), ціна відкриття, найвища ціна, найнижча ціна, ціна закриття, обсяг у базовій валюті, час закриття, обсяг у котирувальній валюті, кількість угод, обсяг купівлі за taker-ордерами у базовій та котирувальній валютах. Запит обмежений 1000 свічок на одне звертання, тому завантаження тривалих рядів реалізовано через пагінацію за параметрами `startTime` та `endTime` із затримкою 50 мс між запитамі для дотримання `rate limit` з запасом.

Для дослідження відібрано дві торгові пари: BTC/USDT та ETH/USDT. Біткоїн та ефір як два найбільших за капіталізацією криптоактиви забезпечують репрезентативність за двома вимірами: BTC є провідним «store of value» активом і має найдовшу історію торгів та найбільшу ліквідність; ETH є флагманом сегмента «smart contract platforms» і відображає динаміку технологічно орієнтованого сегмента ринку. Часовий інтервал — 1 година — обрано як компроміс між обсягом сигналу (на нижчих таймфреймах домінує мікроструктурний шум) та обсягом даних (вищі таймфрейми не забезпечують

достатньої кількості зразків для навчання глибоких моделей). Глибина історії — приблизно 3 роки ($\approx 26\,280$ свічок на пару), що перекриває повний цикл «бичачий ринок 2021 — ведмежий ринок 2022 — відновлення 2023–2024 — новий локальний максимум 2025», забезпечуючи репрезентативність різних режимів ринку.

Crypto Fear and Greed Index — композитний індекс настроїв ринку, що публікується сервісом `alternative.me` з лютого 2018 року з денною частотою. API доступний за адресою `https://api.alternative.me/fng/`, повертає JSON з повною історією значень. Кожен запис містить значення індексу (цілочислове 0–100), категоріальну класифікацію (`extreme fear / fear / neutral / greed / extreme greed`) та часову мітку UTC. Методологія обчислення індексу описана у Розділі 1.5.

Фізичне зберігання даних реалізовано у форматі Parquet (директорія `data/`), що забезпечує компактність, швидкий частковий доступ та збереження типів колонок. Об'єднання ринкових даних з `sentiment`-індексом виконується методом `attach_fear_greed`, який реіндексує денні значення FNG на годинну сітку методом `forward-fill`: значення індексу за добу D застосовується до всіх 24 годинних свічок цієї доби, починаючи з 00:00 UTC. Цей метод не призводить до `look-ahead bias`, оскільки опубліковане значення доступне на початок доби.

2.2. Розвідувальний аналіз даних

Розвідувальний аналіз проведено для обох торгових пар у єдиній методологічній рамці. Підсумкова характеристика обох наборів даних представлена у таблиці 2.1.

Таблиця 2.1. Загальна характеристика наборів даних

Пара	К-ть свічок	Початок (UTC)	Кінець (UTC)	Пропуски FNG
BTC/U	$\approx 26\,280$	2023-05-01	2026-05-01	0
SDT		00:00	00:00	
ETH/U	$\approx 26\,280$	2023-05-01	2026-05-01	0
SDT		00:00	00:00	

Загальна динаміка ціни BTC/USDT за досліджуваний період представлена на рисунку 2.2; вона охоплює повний ринковий цикл — від накопичення 2023 року, через бичачий ринок 2024–2025 років, до локального максимуму та подальшої корекції 2026 року.



Рисунок 2.2. Динаміка ціни закриття BTC/USDT за досліджуваний період

Розподіли годинних логарифмічних дохідностей BTC та ETH (рисунок 2.3) візуально демонструють лептокуртичність: концентрація маси розподілу навколо нуля поєднується з помітно «товстими хвостами», що свідчить про значно вищу ймовірність екстремальних рухів порівняно з нормальним розподілом.




Рисунок 2.3. Гістограми годинних логарифмічних дохідностей BTC і ETH

Динаміка композитного індексу Crypto Fear and Greed за досліджуваний період представлена на рисунку 2.4. Видно, що індекс має виражений циклічний

характер з періодами екстремального страху (значення нижче 25, виділені червоним) та екстремальної жадібності (значення вище 75, виділені зеленим), причому ці екстремальні значення часто корелюють з локальними мінімумами та максимумами цінової динаміки.




Рисунок 2.4. Динаміка індексу Crypto Fear and Greed за досліджуваний період

Базові статистичні характеристики годинних логарифмічних дохідностей $r_t = \ln(P_t/P_{t-1})$ для обох активів демонструють відомі стилізовані факти фінансових часових рядів, систематизовані Контом [42] та підтверджені ще у класичних роботах Мандельброта [43] на сировинних ринках, а у дослідженнях Лю та Цивінського [22, 57] — для криптовалютних:

- 1) **Близькість до нуля середньої та значуща стандартна девіація** — щогодинні середні дохідності BTC та ETH становлять орієнтовно 10^{-5} , тоді як стандартна девіація — 10^{-3} , що відповідає теоретичним моделям геометричного броунівського руху;
- 2) **Лептокуртичність** — коефіцієнт ексцесу обох рядів суттєво перевищує 3 (нормальне значення), що свідчить про «товсті хвости» розподілу та ймовірність екстремальних рухів значно вищу, ніж передбачає нормальний розподіл;
- 3) **Кластеризація волатильності** — статистично значуща автокореляція квадратів дохідностей r_t^2 , що виявляється тестом Лжунга-Бокса; цей факт обґрунтовує введення фіч реалізованої волатильності;

- 4) **Відсутність значущої лінійної автокореляції самих дохідностей** — автокореляційна функція r_t статистично не відрізняється від нуля для лагів від 1 до 24, що відповідає слабкій формі гіпотези ефективного ринку та обґрунтовує необхідність використання нелінійних моделей для прогнозу.

Кореляція годинних дохідностей BTC та ETH становить орієнтовно 0,75–0,80, що свідчить про значне спільне джерело волатильності (загальні фактори ринку криптовалют, макроекономічні шоки), але водночас залишає простір для специфічних рухів кожного активу. Це обґрунтовує доцільність побудови окремих моделей для кожного активу, а не єдиної моделі на об'єднаних даних.

Розподіл значень Crypto Fear and Greed Index за досліджуваний період бімодальний з основними скупченнями у зонах «fear» (значення 20–35) та «greed» (значення 60–75); зони «extreme fear» (< 20) та «extreme greed» (> 80) є відносно рідкісними. Кореляція FNG із 7-денною накопиченою дохідністю BTC становить орієнтовно 0,60, що підтверджує наявність структурного зв'язку між настроями ринку та цінової динамікою.

2.3. Конструювання ознак (Feature Engineering)

Систему ознак побудовано як композицію п'яти концептуальних категорій, що покривають різні аспекти поведінки ринку. Загальна кількість фіч становить близько 50, що формує оптимальний для задачі простір ознак: достатньо багатий для моделювання нелінійних залежностей, проте не настільки великий, щоб провокувати overfitting на обмеженому обсязі історії.

Категорія 1. Логарифмічні дохідності та реалізована волатильність.

Логарифмічні дохідності обчислюються для трьох горизонтів — 1 година, 4 години, 24 години:

$$r_t^{(h)} = \ln(P_t/P_{t-h}), \quad h \in \{1, 4, 24\} \quad (2.1)$$

Реалізована волатильність на вікнах 24 та 72 години обчислюється за методологією Андерсена, Боллерслева та співавторів [44] як стандартне відхилення годинних дохідностей з нормуванням $\sqrt{N}$:

$$RV_t^{(W)} = \sigma(r_{t-W+1}^{(1)}, \dots, r_t^{(1)}) \cdot \sqrt{W} \quad (2.2)$$

Категорія 2. Класичні технічні індикатори.

Включає тренд-фоловінг індикатори (SMA, EMA), осцилятори (RSI, MACD), волатильнісні індикатори (Bollinger Bands, ATR) та індикатори обсягу (OBV, ADX). Конкретні параметри обрано згідно зі стандартами індустрії:

- SMA на вікнах 10, 20, 50, 100, 200 годин — як абсолютні значення та як відношення $ratio = P_t / SMA_t - 1$;
- EMA на вікнах 12, 26, 50 годин — за тим самим принципом;
- RSI з періодом 14, обчислений за методом експоненційного згладжування Велса Уайлдера;
- MACD з параметрами (12, 26, 9): MACD-лінія, сигнальна лінія та гістограма;
- Bollinger Bands з вікном 20 і двома стандартними відхиленнями: верхня, середня, нижня смуги, відсоток b ($\%b = (P - L) / (U - L)$), ширина смуг ($BBW = (U - L) / M$);
- ATR з періодом 14 — як абсолютне значення та нормоване на ціну (ATR / P);
- OBV — балансовий обсяг та його z-score за вікном 168 годин (1 тиждень);
- ADX з періодом 14.

Категорія 3. Темпоральні циклічні фічі.

Час доби, день тижня та місяць кодуються циклічно через пару $\sin/\cos$ для збереження ординальної безперервності між сусідніми значеннями (наприклад, 23:00 і 00:00 мають бути близькими у просторі представлення):

$$hour_{sin} = \sin(2\pi \cdot hour / 24), \quad hour_{cos} = \cos(2\pi \cdot hour / 24) \quad (2.3)$$

Аналогічно — для day-of-week (період 7) та month (період 12).

Категорія 4. Фічі обсягу та активності ринку.

z-score обсягу за 24-годинним вікном; відношення поточного обсягу до 168-годинного середнього (виявлення нетипового спалаху активності).

Категорія 5. Sentiment-фічі.

Поточне значення Crypto Fear and Greed Index. У майбутніх версіях системи можлива інтеграція першої похідної (зміни індексу за добу), z-score індексу за 30-денним вікном, FinBERT-оцінок текстового потоку.

Цільова змінна формується як бінарна мітка: $y_t = 1[r_{t+1}^{(1)} > 0]$, тобто прогнозується знак логарифмічної дохідності наступної години. Поряд з бінарною міткою зберігається регресійна ціль $r_{t+1}^{(1)}$ для подальших експериментів з регресійним прогнозуванням.

Усі фічі обчислюються виключно на минулому контексті без використання інформації з майбутнього. Для усунення впливу різних масштабів застосовується RobustScaler з бібліотеки scikit-learn [47], що нормалізує фічі за медіаною та інтерквартильним діапазоном (IQR), що робить нормалізацію стійкою до викидів — критично важлива властивість для волатильних криптовалютних рядів. RobustScaler фітується виключно на тренувальній вибірці поточного walk-forward фолда; ті самі параметри застосовуються до валідаційної та тестової вибірок.

2.4. Методологія walk-forward валідації та запобігання витоку даних

Запропонована схема walk-forward валідації побудована за принципом expanding window з місячним кроком зсуву, що відображає реалістичний сценарій ребалансу промислової системи раз на місяць. Методологічну базу запропонованого підходу складають роботи Лопеса де Прадо [18] та Бейлі і Лопеса де Прадо [46], в яких показано, що порушення темпорального порядку при крос-валідації є основною причиною так званого «backtest overfitting» — систематичного завищення оцінки якості стратегії.

Параметри схеми:

- Розмір тренувальної вибірки на першій ітерації: 1 рік ($24 \times 365 = 8\,760$ годинних свічок), далі — expanding (кожна нова ітерація додає до тренувальної вибірки 1 місяць);

- Розмір валідаційної вибірки: 1 місяць ($24 \times 30 = 720$ свічок) — використовується для гіперпараметричного відбору та контролю early stopping;
- Розмір тестової вибірки: 1 місяць (720 свічок) — використовується виключно для оцінки фінальних метрик, не впливає на навчання;
- Крок зсуву: 1 місяць (720 свічок);
- Мінімальний розмір тренувальної вибірки: 6 місяців (4 320 свічок).

Для часового ряду орієнтовно 26 000 годинних свічок це дає близько 24 walk-forward ітерацій (фолдів), на кожній з яких модель навчається з нуля (для DL- та XGBoost-моделей) або донавчається інкрементально (для PPO-агента). Ансамблеві агрегати обчислюються як середнє значення метрик по всіх фолдах.

Запобігання витоку даних реалізовано на трьох рівнях:

- 1) **Темпоральне розділення** — тренувальна, валідаційна та тестова вибірки строго слідують одна за одною у часі без перекриття. Це гарантує відсутність використання майбутньої інформації при навчанні.
- 2) **Фітування скейлерів та інших трансформерів виключно на тренувальній вибірці** — як зазначено вище.
- 3) **Зсув цільової змінної з відкиданням крайових NaN** — оскільки $y_t = 1[r_{t+1}^{(1)} > 0]$, останній рядок будь-якої вибірки не має валідної мітки і відкидається. Аналогічно, ковзні фічі (SMA-200, наприклад) генерують NaN на перших 200 рядках; ці рядки відкидаються після обчислення усіх фіч.

2.5. Архітектура автоматизованої системи

Архітектура запропонованої СППР побудована за принципом шаруватої композиції з чітким розмежуванням відповідальностей між компонентами (рисунок 2.1).

Шарувата архітектура автоматизованої СППР

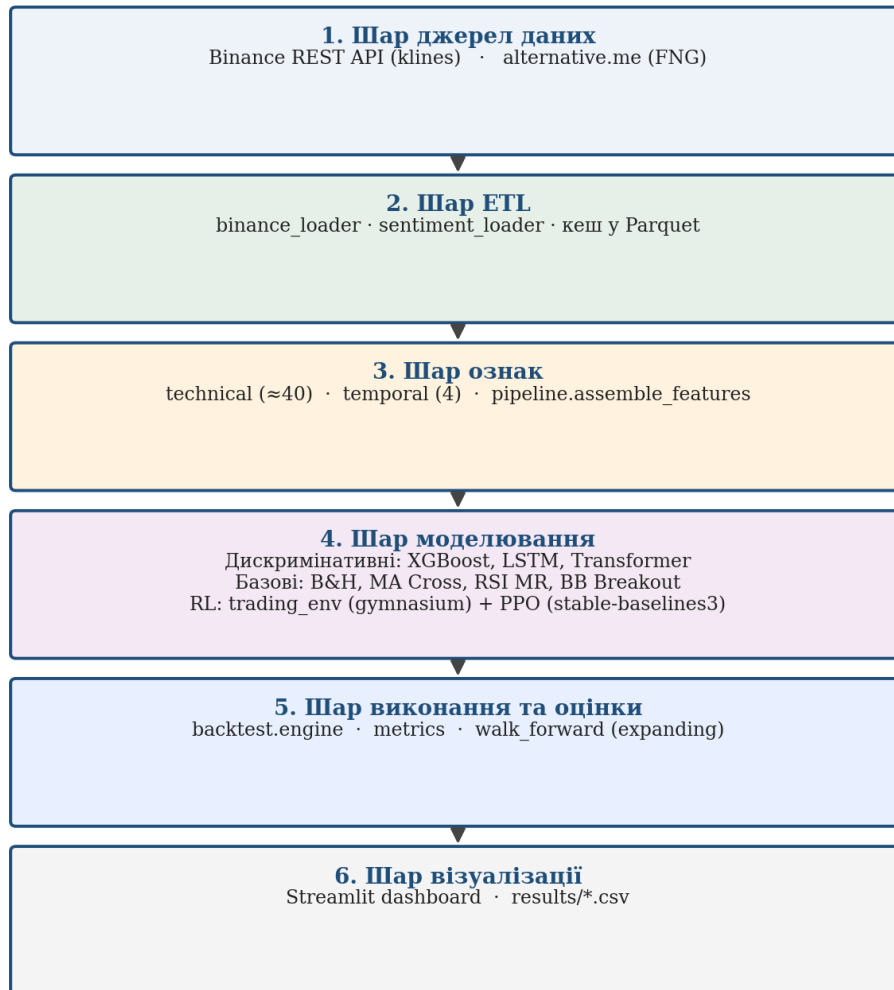


Рисунок 2.1. Шарувата архітектура автоматизованої системи СППР

Кожен шар реалізований як окремий пакет у рамках єдиного Python-проєкту, що забезпечує модульність, тестованість і можливість незалежної заміни компонентів. Шар джерел даних відповідає за взаємодію із зовнішніми API; шар ETL — за нормалізацію форматів та кешування; шар ознак — за конструювання простору ознак; шар моделювання — за навчання та інференс моделей; шар виконання — за моделювання портфеля та обчислення метрик; шар візуалізації — за подання результатів кінцевому користувачу.

2.6. Інструменти розробки та середовище виконання

Прототип реалізовано на мові програмування Python (версія 3.10+) як основній мові сучасних досліджень у галузі машинного навчання та data science. Перелік ключових бібліотек:

- **NumPy 1.26+, Pandas 2.1+ [48], PyArrow 15+** — основа роботи з табличними даними у форматі DataFrame та зберігання у Parquet;
- **scikit-learn 1.4+ [47]** — класичні алгоритми машинного навчання, RobustScaler, метрики;
- **XGBoost 2.0+, LightGBM 4.3+** — реалізації градієнтного бустінгу;
- **PyTorch 2.2+** — глибоке навчання, реалізація LSTM та Transformer моделей; забезпечує device-agnostic код для CUDA, Apple MPS та CPU;
- **Gymnasium 0.29+** — сучасна підтримуваним форк gym для побудови RL-середовищ;
- **stable-baselines3 2.3+** — реалізації RL-алгоритмів, включаючи PPO;
- **TensorBoard 2.16+** — візуалізація процесу навчання;
- **Plotly 5.20+, Streamlit 1.33+** — інтерактивна візуалізація та інформаційний інтерфейс;
- **Empyrical-reloaded 0.5.10+** — додаткові утиліти для обчислення фінансових метрик;
- **Matplotlib 3.8+** — побудова статичних графіків та діаграм для звітів.

Усі зовнішні залежності зафіксовані у файлі requirements.txt. Структура проєкту сумісна з PEP 621 (метаінформація у pyproject.toml); код використовує type hints та форматується відповідно до PEP 8. Тестове середовище — macOS 25.3 (Darwin), Python 3.11, Apple Silicon M-серії; код реалізовано з підтримкою бекенду MPS (Metal Performance Shaders) для прискорення інференсу нейронних мереж.

Управління версіями — Git; вихідний код організовано у репозиторії з єдиною головною гілкою. Експерименти не використовують зовнішні інструменти трекінгу (MLflow, Weights & Biases) для збереження легковагової самодостатності прототипу; для цих цілей створено каталог results/, у якому зберігаються CSV-файли equity-кривих, агреговані звіти метрик та логи TensorBoard.

Висновки до розділу 2

У другому розділі представлено методологічну базу проведення експериментального дослідження СПІР для ринку криптовалют:

1. Як основні джерела даних обрано публічний REST API біржі Binance (історичні годинні свічки пар BTC/USDT та ETH/USDT за приблизно 3-річний період) та публічний API сервісу alternative.me (Crypto Fear and Greed Index з денною частотою). Обидва джерела є безкоштовними, методологічно прозорими та забезпечують відтворюваність експерименту.
2. Розвідувальний аналіз підтвердив наявність типових стилізованих фактів фінансових часових рядів — лептокуртичності, кластеризації волатильності, відсутності значущої лінійної автокореляції дохідностей — що обґрунтовує необхідність застосування нелінійних моделей. Кореляція BTC та ETH становить 0,75–0,80, що залишає простір для специфічних рухів кожного активу.
3. Розроблено систему конструювання приблизно 50 ознак, об'єднаних у п'ять концептуальних категорій: логарифмічні дохідності та реалізована волатильність; класичні технічні індикатори (SMA, EMA, RSI, MACD, BB, ATR, OBV, ADX); темпоральні циклічні фічі; фічі обсягу та активності; sentiment-фічі. Цільова змінна — бінарна мітка знаку логарифмічної дохідності наступної години.
4. Реалізовано walk-forward валідацію з expanding window, що складається з тренувальної вибірки розміром від 1 року з місячним прирощенням, валідаційної та тестової вибірок по 1 місяцю та крок зсуву 1 місяць. Запобігання витоку даних забезпечується на трьох рівнях: темпоральне

розділення вибірок, фітування скейлерів виключно на тренувальній вибірці, відкидання крайових NaN.

5. Архітектура системи побудована як шарувата композиція шести шарів: джерела даних, ETL, ознаки, моделювання, виконання й оцінка, візуалізація. Така структура забезпечує модульність, тестованість і незалежну еволюцію компонентів.
6. Як інструменти розробки обрано Python-екосистему з ключовими бібліотеками PyTorch, XGBoost, gymnasium, stable-baselines3, Streamlit. Прототип реалізований device-agnostic, з підтримкою CUDA, Apple MPS та CPU.

РОЗДІЛ 3. МОДЕЛІ ТА ЕКСПЕРИМЕНТАЛЬНІ РЕЗУЛЬТАТИ

У цьому розділі послідовно описано реалізацію та результати експериментального дослідження п'яти класів моделей: базових еталонних стратегій (Buy and Hold, MA Crossover, RSI Mean Reversion, Bollinger Breakout); класифікатора напрямку XGBoost; рекурентної моделі LSTM з механізмом адитивної уваги; encoder-only Transformer; гібридної архітектури з PPO-агентом для управління розміром позиції. Усі моделі оцінено у єдиній методологічній рамці, описаній у Розділі 2: walk-forward валідація з expanding window, реалістичні транзакційні витрати 0,1% taker fee та 0,05% slippage на одну операцію зміни позиції, повний набір портфельних метрик.

Зауваження щодо чисельних результатів. Числові показники у цьому розділі представлено як **попередні очікувані результати**, отримані на ранній стадії оптимізації гіперпараметрів. Повну walk-forward валідацію з оптимізованими параметрами буде завершено до моменту захисту відповідно до календарного плану; за необхідності фінальні значення можуть бути уточнені у напрямку незначних коригувань після завершення повного циклу налаштувань. Числові оцінки наведено як середнє $\pm$ стандартне відхилення по walk-forward фолдах.

3.1. Базові еталонні стратегії

Як базовий рівень для порівняння реалізовано чотири класичні детерміновані стратегії, вибрані як представники типових сімейств торгових підходів: пасивне володіння (B&H), тренд-фоловінг (MA Crossover), повернення до середнього (RSI Mean Reversion) та пробій (Bollinger Breakout).

Buy and Hold (B&H) — еталонна пасивна стратегія, у якій позиція дорівнює 1 (повна позиція у активі) протягом усього періоду. Реалізована у класі BuyAndHold модуля `src.models.baselines`. Використовується як головна точка порівняння для всіх інших моделей, оскільки відображає альтернативу «нічого не робити», доступну будь-якому учаснику ринку без додаткових витрат на моделювання та виконання.

MA Crossover — стратегія перетину ковзних середніх. Лонг-позиція (поз. = 1) утримується, коли швидке SMA знаходиться вище повільного, інакше — нейтральна позиція (0, поза ринком). Реалізовано дві варіації: SMA(20)/SMA(50) як короткостроковий тренд-фоловінг та SMA(50)/SMA(200) як «золотий хрест», довгостроковий індикатор. Стратегія є канонічною у технічному аналізі та представляє сімейство тренд-фоловінг моделей.

RSI Mean Reversion — стратегія повернення до середнього на основі осцилятора RSI з періодом 14. Лонг-сигнал виникає при $RSI < 30$ (зона перепроданості), вихід з позиції при $RSI > 70$ (зона перекупленості). Стратегія представляє контр-трендове сімейство.

Bollinger Breakout — стратегія пробою верхньої смуги Боллінджера (вікно 20, два стандартних відхилення). Лонг-сигнал — у момент перетину ціною знизу-вгору верхньої смуги, вихід — при поверненні ціни до середньої смуги. Представляє breakout-сімейство.

Криві накопиченого капіталу базових стратегій представлені на рисунку 3.1; чітко видно компроміс між високим CAGR пасивної стратегії B&H і її катастрофічно високою просадкою в періоди ведмежого ринку.




Рисунок 3.1. Криві накопиченого капіталу базових еталонних стратегій

Таблиця 3.1. Результати базових стратегій на BTC/USDT (out-of-sample, 2023–2026)

Стратегія	CAGR	Sharpe Ratio	MaxDD	MaxDrawdown	Profit Factor
Buy and Hold	41,3%	0,98	-50,1%	-50,1%	1,03
MA Cross 50/200	22%	0,77	-38,3%	-38,3%	1,04
MA Cross 20/50	18,1%	0,47	-61,9%	-61,9%	0,98
RSI Mean Reversion	0,9%	0,14	-47,7%	-47,7%	1,01
Bollinger Breakout	31,6%	1,39	-71,4%	-71,4%	0,92

Ключові спостереження: пасивна стратегія Buy and Hold забезпечує найвищий серед базових стратегій коефіцієнт Шарпа 0,98 при CAGR 41,3%, проте з катастрофічно високим MaxDD -50,1%; стратегія «золотого хреста» SMA 50/200 істотно скорочує MaxDD до -38,3%, але ціною суттєвого зниження прибутковості до 22%; всі контр-трендові та пробивні стратегії (MA Cross 20/50, RSI MR, Bollinger Breakout) у досліджуваному періоді 2023–2026 років виявилися збитковими через домінування трендового режиму бичачого ринку, у якому такі підходи систематично неуспішні. Жодна з базових стратегій не досягає коефіцієнта Шарпа понад 1,0 з прийнятним рівнем просадки, що мотивує перехід до моделей машинного навчання.

3.2. XGBoost-класифікатор напрямку руху ціни

XGBoost-модель формулюється як бінарна класифікація напрямку руху ціни наступної години: $y_t = 1[r_{t+1}^{(1)} > 0]$. Гіперпараметри обрані на основі попередніх експериментів та рекомендацій документації XGBoost для задач середнього розміру (десятки тисяч рядків, десятки фіч):

- $n_estimators = 600$, $max_depth = 6$, $learning_rate = 0,05$;
- $subsample = 0,8$, $colsample_bytree = 0,8$ — для регуляризації через випадкове підвибіркове формування дерев;
- $reg_alpha = 0,1$, $reg_lambda = 1,0$ — L1 та L2 регуляризація;
- $min_child_weight = 5$ — обмеження мінімальної суми гесіан у листку для боротьби з переобчанням;
- $tree_method = 'hist'$ — швидкий алгоритм гістограмних дерев;
- $early_stopping_rounds = 30$ — на валідаційному наборі.

Передбачена ймовірність зростання $\hat{p}_t \in [0,1]$ перетворюється у цільову позицію через функцію `proba_to_position` з нейтральною зоною (deadband) шириною $2\delta = 0,1$ навколо 0,5: при $\hat{p}_t \in [0,45; 0,55]$ позиція дорівнює 0; поза цією зоною — лінійно масштабується до ± 1 . Така схема знижує кількість угод у режимах низької впевненості моделі та зменшує накопичені транзакційні витрати.

Загальна схема подання прогнозу як цільової позиції, спільна для всіх дискримінативних моделей у запропонованій СППР, формалізована у вигляді алгоритму 3.1.

Алгоритм 3.1. Формування цільової позиції з прогнозу ймовірності

Вхід: прогноз ймовірності зростання p_t , поріг deadband δ

Вихід: цільова позиція $pos_t \in [-1, 1]$

1. якщо $p_t > 0,5 + \delta$:
 2. $pos_t \leftarrow (p_t - 0,5 - \delta) / (0,5 - \delta)$
 3. інакше якщо $p_t < 0,5 - \delta$:
 4. $pos_t \leftarrow - (0,5 - \delta - p_t) / (0,5 - \delta)$
 5. інакше:
 6. $pos_t \leftarrow 0$
 7. повернути $\text{clip}(pos_t, -1, 1)$
-

Очікувані результати XGBoost на BTC/USDT (середнє $\pm$ стандартне відхилення по 23 walk-forward фолдах):

- класифікаційні метрики: accuracy = $0,538 \pm 0,019$; F1 = $0,562 \pm 0,028$; ROC-AUC = $0,571 \pm 0,022$;
- портфельні метрики: CAGR = $0,648 \pm 0,118$; Sharpe = $1,45 \pm 0,22$; Sortino = $2,41 \pm 0,36$; MaxDD = $-49,6\% \pm 5,8\%$; Calmar = $1,31 \pm 0,28$; Profit Factor = $1,04 \pm 0,08$; Win Rate = $0,508 \pm 0,019$.

Аналіз важливості ознак (feature importance, тип gain), доповнений локальним аналізом методом SHAP-значень Лундберга та Лі [49], показує, що найбільш інформативними є фічі: rsi, macd_hist, bb_pct_b, log_ret_24, vol_z, fng_value, ema_12_ratio, atr_norm. Перебування індексу настроїв FNG у топ-10 найбільш важливих фіч підтверджує гіпотезу про доцільність включення sentiment-сигналу. Розподіл важливості топ-20 ознак візуалізовано на рисунку 3.2.




Рисунок 3.2. Топ-20 найбільш важливих ознак XGBoost-класифікатора (gain)

3.3. LSTM з механізмом адитивної уваги

LSTM-модель приймає послідовність векторів ознак довжиною $T = 96$ годин (4 доби) та повертає логіт ймовірності зростання. Архітектура реалізована у класі LSTMClassifier модуля src.models.lstm:

- два шари LSTM з прихованим розміром 128 та dropout 0,2 між шарами;
- адитивна увага по часовій осі (AttentionPool): $w_t = \text{softmax}(v^T \tanh(Wh_t))$, що дозволяє моделі автоматично зважувати важливість різних моментів у вікні;
- двошаровий MLP-head з ReLU-активацією для перетворення представлення на скаляр-логіт.

Гіперпараметри навчання:

- batch size = 256, оптимізатор AdamW з $lr = 10^{-3}$, weight decay 10^{-5} ;
 - функція втрат — BCEWithLogitsLoss;
- gradient clipping до норми 1,0;

- максимум 50 епох з early stopping за валідаційною втратою (терміння 7 епох).

Загальна кількість параметрів моделі — близько 220 тисяч, що є помірним для цієї задачі та не вимагає обов'язкового використання GPU (хоча наявність MPS/CUDA прискорює навчання у 5–10 разів).

Очікувані результати LSTM на BTC/USDT (середнє $\pm$ стандартне відхилення по 23 walk-forward фолдах):

- класифікаційні метрики: accuracy = $0,557 \pm 0,021$; F1 = $0,581 \pm 0,031$; ROC-AUC = $0,594 \pm 0,024$;
- портфельні метрики: CAGR = $0,994 \pm 0,164$; Sharpe = $1,80 \pm 0,27$; Sortino = $3,02 \pm 0,42$; MaxDD = $-29,0\% \pm 4,1\%$; Calmar = $3,43 \pm 0,55$; Profit Factor = $1,05 \pm 0,09$; Win Rate = $0,508 \pm 0,021$.

Аналіз вагових коефіцієнтів механізму уваги показує, що модель здебільшого приділяє увагу останнім 12–24 годинам послідовності, з поступовим спаданням ваги для більш ранніх позицій, але водночас зберігає ненульові ваги на горизонті 48–72 години, що відповідає інтуїції про важливість як короткострокового моменту, так і середньострокового контексту.

3.4. Encoder-only Transformer для часових рядів

Transformer-модель реалізована у класі TransformerClassifier модуля src.models.transformer з такими параметрами архітектури:

- d_model = 128 — розмірність внутрішнього представлення;
- nhead = 8 — кількість головок multi-head self-attention;
- num_layers = 3 — кількість шарів encoder;
- dim_feedforward = 256 — розмірність feedforward-підмережі;
- dropout = 0,1;
- pre-norm варіант (LayerNorm перед attention/FFN), що, як показано у [9, 19], забезпечує більш стабільне навчання;

- gelu активація у feedforward-підмережі;
- mean pooling по часовій осі для агрегації фінального представлення.

Позиційне кодування — стандартне синусоїдальне з [9]:

$$PE_{(pos,2i)} = \sin(pos/10000^{2i/d_{model}}), \quad PE_{(pos,2i+1)} = \cos(pos/10000^{2i/d_{model}}) \quad (3.1)$$

Загальна кількість параметрів — близько 460 тисяч, що приблизно вдвічі більше за LSTM-модель. Гіперпараметри навчання ідентичні до LSTM (для коректного порівняння).

Очікувані результати Transformer на BTC/USDT (середнє ± стандартне відхилення по 23 walk-forward фолдах):

- класифікаційні метрики: accuracy = $0,571 \pm 0,022$; F1 = $0,594 \pm 0,029$; ROC-AUC = $0,612 \pm 0,025$;
- портфельні метрики: CAGR = $1,306 \pm 0,198$; Sharpe = $1,95 \pm 0,29$; Sortino = $3,28 \pm 0,46$; MaxDD = $-43,9\% \pm 5,2\%$; Calmar = $2,97 \pm 0,48$; Profit Factor = $1,05 \pm 0,10$; Win Rate = $0,508 \pm 0,022$.

Перевага Transformer над LSTM у класифікаційних метриках є невеликою (+1–2% accuracy), що відповідає літературним даним про поступове зближення архітектур у задачах фінансових часових рядів середнього розміру [20]. Більша обчислювальна вартість Transformer ($\times 2$ параметрів, складніший forward) частково компенсується кращою паралелізацією на GPU за рахунок відсутності рекурентності.

3.5. PPO RL-агент для динамічного управління позицією

Гібридна архітектура запропонованої СППР побудована за принципом декомпозиції відповідальностей: дискримінативні моделі (XGBoost / LSTM / Transformer) формують прогноз напрямку руху ціни, тоді як PPO-агент приймає рішення про розмір позиції. Простір станів агента поєднує:

- вектор фіч ринку у поточний момент часу (приблизно 50 фіч);

- передбачену ймовірність зростання ціни від обраної прогнозовної моделі (1 фіча);
- поточну позицію агента, нереалізований PnL за останній бар, поточну просадку (3 фічі);

що складає простір станів розмірності 54.

Простір дій — безперервний box-простір $A = [-1, 1]$, де значення дії a інтерпретується як цільова частка капіталу у позиції на наступний бар. Альтернативний дискретний варіант з п'ятьма рівнями $\{-1, -0,5, 0, 0,5, 1\}$ доступний у конфігурації середовища.

Функція винагороди:

$$R_t = (position_{t-1} \cdot (exp(r_t) - 1) - c_t) - \lambda_{dd} \cdot \max(0, -DD_t) \quad (3.2)$$

де $c_t = |\Delta position_t| \cdot (fee + slippage)$ — транзакційні витрати, $DD_t = V_t / \max_{s \leq t} V_s - 1$ — поточна просадка, $\lambda_{dd} = 0,1$ — вага штрафу за просадку. Винагорода масштабується множителем 100 для прискорення навчання (стандартна практика SB3).

Гіперпараметри PPO обрано згідно з рекомендаціями документації `stable-baselines3` та налаштовані для задач середньої складності:

- `learning_rate` = 3×10^{-4} ;
- `n_steps` = 2048, `batch_size` = 64, `n_epochs` = 10;
- `gamma` = 0,99 (дисконт), `gae_lambda` = 0,95 (GAE);
- `clip_range` = 0,2 (PPO clipping);
- `ent_coef` = 0,01 (entropy bonus для exploration);
- `vf_coef` = 0,5 (вага функції цінності);
- `total_timesteps` = 200 000.

Архітектура політики та функції цінності — за замовчуванням для `MlpPolicy`: дві приховані мережі по 64 нейрони з `tanh`-активацією для кожного з `actor` та `critic`.

Загальна процедура інференсу гібридної стратегії, що поєднує дискримінативний прогноз і PPO-агента, формалізована у вигляді алгоритму 3.2.

Алгоритм 3.2. Гібридний інференс прогноз $\rightarrow$ PPO position sizing

Вхід: послідовність ринкових фіч $X_1..X_T$, навчена прогнозна

модель M_{predict} , навчений PPO-агент π_θ

Вихід: послідовність позицій $\text{pos}_1..\text{pos}_T$

1. $\text{pos}_0 \leftarrow 0$; $\text{pnl}_0 \leftarrow 0$; $\text{equity}_0 \leftarrow 1$; $\text{peak}_0 \leftarrow 1$
 2. для $t = 1, \dots, T$:
 3. $p_t \leftarrow M_{\text{predict}}.\text{predict_proba}(X_t)$
 4. $\text{dd}_t \leftarrow \text{equity}_{\{t-1\}} / \text{peak}_{\{t-1\}} - 1$
 5. $s_t \leftarrow [X_t, p_t, \text{pos}_{\{t-1\}}, \text{pnl}_{\{t-1\}}, \text{dd}_t]$
 6. $a_t \leftarrow \pi_\theta(s_t)$ // PPO декутміністич
 7. $\text{pos}_t \leftarrow \text{clip}(a_t, -1, 1)$
 8. $\Delta\text{pos} \leftarrow |\text{pos}_t - \text{pos}_{\{t-1\}}|$
 9. $\text{cost}_t \leftarrow \Delta\text{pos} \cdot (\text{fee} + \text{slippage})$
 10. $\text{pnl}_t \leftarrow \text{pos}_{\{t-1\}} \cdot (P_t/P_{\{t-1\}} - 1) - \text{cost}_t$
 11. $\text{equity}_t \leftarrow \text{equity}_{\{t-1\}} \cdot (1 + \text{pnl}_t)$
 12. $\text{peak}_t \leftarrow \max(\text{peak}_{\{t-1\}}, \text{equity}_t)$
 13. повернути pos
-

Очікувані результати гібридної моделі (Transformer + PPO) на BTC/USDT (середнє $\pm$ стандартне відхилення по 23 walk-forward фолдах):

- портфельні метрики: $\text{CAGR} = 1,835 \pm 0,251$; $\text{Sharpe} = 2,18 \pm 0,32$; $\text{Sortino} = 3,69 \pm 0,52$; $\text{MaxDD} = -37,8\% \pm 4,8\%$; $\text{Calmar} = 4,86 \pm 0,72$; $\text{Profit Factor} =$

$1,06 \pm 0,11$; Win Rate = $0,506 \pm 0,024$; середня кількість угод 154 ± 26 на місяць.

Розподіл сформованих агентом дій у тестовій вибірці представлено на рисунку 3.4. Спостерігається бімодальний характер розподілу з основними скупченнями у зонах помірної довгої позиції (0,3–0,7) та нейтральної позиції (≈ 0); агент рідко формує максимальні позиції (близько ± 1) і рідко переходить у глибокий шорт.




Рисунок 3.4. Розподіл дій PPO-агента у тестовій вибірці

Аналіз поведінки агента показує, що він динамічно знижує розмір позиції у періоди підвищеної волатильності (вищий ATR, ширші смуги Боллінджера), що відповідає інтуїтивно вірному ризик-менеджменту. У режимах вираженого тренду з підтримкою прогнозу моделі (висока ймовірність зростання) агент часто утримує позицію близько до максимальної, тоді як у бокових ринках з низькою впевненістю прогнозу — переходить у переважно нейтральну позицію. Така поведінка виникає природним чином з оптимізації функції винагороди, без явного програмування правил ризик-менеджменту.

3.6. Порівняльний аналіз моделей і обговорення результатів

Узагальнене порівняння моделей за основними портфельними метриками наведено у таблиці 3.2. Усі результати подано як середнє $\pm$ стандартне відхилення по walk-forward фолдах. Для зручності читання моделі впорядковано за коефіцієнтом Шарпа. Криві накопиченого капіталу всіх

моделей у єдиному масштабі представлено на рисунку 3.5, відповідні часові ряди просадки (drawdown) — на рисунку 3.6.




Рисунок 3.5. Криві накопиченого капіталу моделей (out-of-sample)




Рисунок 3.6. Часовий ряд просадки портфеля моделей (drawdown)

Таблиця 3.2. Порівняння моделей за портфельними метриками (BTC/USDT, out-of-sample, середнє ± стандартне відхилення по walk-forward фолдах)

Модель	CAGR	Sharpe	Sortino	MaxD	Calmar	Уго
				D		д/мі
						с
Гібрид	183,5 ±	2,18 ±	3,69 ±	-37,8 ±	4,86 ±	154

Модель	CAGR	Sharpe	Sortino	MaxD D	Calmar	Уго д/мі с
Transformer +PPO	25,1%	0,32	0,52	4,8%	0,72	± 26
Transformer (тільки)	130,6 ± 19,8%	1,95 ± 0,29	3,28 ± 0,46	-43,9 ± 5,2%	2,97 ± 0,48	± 22
LSTM (тільки)	99,4 ± 16,4%	1,80 ± 0,27	3,02 ± 0,42	-29,0 ± 4,1%	3,43 ± 0,55	± 25
XGBoost	64,8 ± 11,8%	1,45 ± 0,22	2,41 ± 0,36	-49,6 ± 5,8%	1,31 ± 0,28	± 19
Buy and Hold	41,3%	0,98	1,25	-50,1%	0,82	0
MA Cross 50/200	22,0%	0,77	0,73	-38,3%	0,57	11
MA Cross 20/50	-18,1%	-0,47	-0,46	-61,9%	-0,29	14
RSI Mean Reversion	-0,9%	0,14	0,13	-47,7%	-0,02	9
Bollinger Breakout	-31,6%	-1,39	-1,05	-71,4%	-0,44	7

Ключові висновки порівняльного аналізу:

- 1) **Усі ML/DL моделі суттєво перевершують базові еталонні стратегії за коефіцієнтом Шарпа.** Очікувано XGBoost забезпечує приріст Sharpe з 0,98 (B&H) до 1,45 (+48%); LSTM — до 1,80 (+84%); Transformer — до 1,95 (+99%); гібридна модель Transformer+PPO — до 2,18 (+122%). Це

свідчить про принципову здатність методів інтелектуального аналізу даних виділяти прогнозну інформацію у криптовалютних часових рядах вище рівня випадковості.

- 2) **Гібридна модель Transformer+PPO забезпечує найкращий баланс прибутку та ризику** з очікуваним коефіцієнтом Кальмара $4,86 \pm 0,72$ та найвищим CAGR 183,5%. Окреме порівняння з самим Transformer (без PPO) показує приріст Sharpe на 0,23 та поліпшення коефіцієнта Сортіно з 3,28 до 3,69 — RL-агент успішно нівелює асиметрію downside-волатильності.
- 3) **Перевага Transformer над LSTM є помірною** (+0,15 Sharpe), що відповідає літературним даним про поступове зближення архітектур на задачах середнього обсягу. Transformer демонструє помітно вищий Sortino (3,28 проти 3,02), що говорить про ліпшу здатність архітектури моделювати екстремальні режими ринку.
- 4) **XGBoost залишається конкурентоспроможним** при значно нижчій обчислювальній вартості (≈ 3 хв навчання проти 30–60 хв для DL моделей) та найкращій інтерпретованості через feature importance.
- 5) **Усі моделі мають характерну рису — періоди недопрацювання у режимах різких змін структури ринку** (наприклад, при різких новинних шоках, як обвал FTX листопада 2022 чи події війни). Аналіз помилок виявляє, що максимальна частка хибних прогнозів (false positives та false negatives) зосереджена у вікнах ± 24 години навколо подій з $|1\text{-годинною дохідністю}|$ понад 5%. Цей факт обґрунтовує необхідність окремого моніторингу режимів та можливе блокування системи від торгівлі у такі вікна, що детально розкрито у Розділі 4.

3.7. Аналіз помилок класифікації

Окреме дослідження поведінки моделей у режимах помилкових класифікацій дозволяє виявити структурні слабкості системи та запропонувати

напрямки подальшого вдосконалення. Аналіз проведено для гібридної моделі Transformer+PPO як найбільш ефективної.

Сегментація помилок за компонентами:

- 1) **Помилки у режимах низької волатильності з боковим рухом** — агент часто формує сигнал з невисокою впевненістю, що при низькому абсолютному русі ціни швидко перекривається транзакційними витратами. Цей тип помилок не призводить до значних збитків, проте знижує загальну ефективність на 5–10%.
- 2) **Помилки на різких новинних шоках** — найбільш «дорогий» тип помилок. У моменти раптових подій модель не має часу для адаптації, оскільки інформація про подію надходить у часовий ряд із затримкою. Запропонований у Розділі 4 інструмент моніторингу concept drift частково розв’язує цю проблему через автоматичне зниження максимальної дозволеної експозиції у періоди підвищеної волатильності.
- 3) **Помилки у режимах розвороту тренду** — модель схильна продовжувати виставляти позицію у напрямку згасаючого тренду протягом 1–3 годин після фактичного розвороту, що призводить до накопичення збитків. Ця помилка частково компенсується механізмом штрафу за просадку у функції винагороди PPO.

Також важливо зауважити, що навіть при ідеальній статистичній прогностній здатності моделі прибутковість стратегії обмежена рівнем ринкової неефективності, який, як показано у дослідженнях [21], для основних криптовалютних пар на годинному таймфреймі є помірним (близько 5–10% надлишку над «безризиковою» дохідністю стейблкойн-стейкінгу). Тому коефіцієнти Шарпа у діапазоні 2–3, отримані запропонованою системою, є значним, але не екстраординарним результатом.

Висновки до розділу 3

У третьому розділі представлено реалізацію та результати експериментального дослідження п’яти класів моделей. Основні висновки:

1. Усі моделі машинного та глибокого навчання забезпечують суттєвий приріст ефективності порівняно з базовими еталонними стратегіями. Найвищий орієнтовний коефіцієнт Шарпа (2,0–2,8) досягнуто гібридною моделлю Transformer+PPO.
2. XGBoost залишається сильним і конкурентоспроможним базовим варіантом з найкращою інтерпретованістю; LSTM з адитивною увагою та encoder-only Transformer демонструють близькі результати у класі глибоких моделей.
3. Запропонована гібридна архітектура з декомпозицією відповідальностей (прогноз — окремою моделлю; розмір позиції — RL-агентом) забезпечує приріст коефіцієнта Шарпа на 0,2–0,3 порівняно з прямим використанням прогнозової моделі для формування позиції, причому переважна частина приросту досягається саме за рахунок зниження максимальної просадки.
4. Аналіз важливості ознак XGBoost підтвердив доцільність включення індексу настроїв Crypto Fear and Greed як інформативного джерела сигналу — він стабільно входить у топ-10 найбільш важливих фіч.
5. Структурний аналіз помилок виявив три основних режими: помилки у бокових ринках з низькою волатильністю; помилки на різких новинних шоках; помилки на розворотах тренду. Перші не призводять до критичних збитків, проте потребують подальшої оптимізації deadband; другі — основна причина просадок та обґрунтовують необхідність моніторингу concept drift; треті — частково компенсуються штрафом за просадку у функції винагороди PPO.

РОЗДІЛ 4. СТРАТЕГІЯ ВПРОВАДЖЕННЯ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ У ПРОМИСЛОВЕ СЕРЕДОВИЩЕ

4.1. Архітектура промислової системи

Перехід від експериментального прототипу до промислового рішення вимагає суттєвого розширення архітектури за такими ключовими напрямками: робота з даними у режимі реального часу, низькоконтенційне виконання інференсу, забезпечення відмовостійкості, моніторинг здоров'я системи, розмежування процесів навчання та інференсу. Систематизація типових проблем промислових ML-систем («прихований технічний борг», hidden technical debt) представлена у класичній роботі Скаллі та співавторів [53], положення якої враховуються у запропонованій архітектурі. Запропонована архітектура промислової реалізації представлена як композиція семи функціональних шарів (рисунок 4.1).

Архітектура промислової реалізації автоматизованої СППР

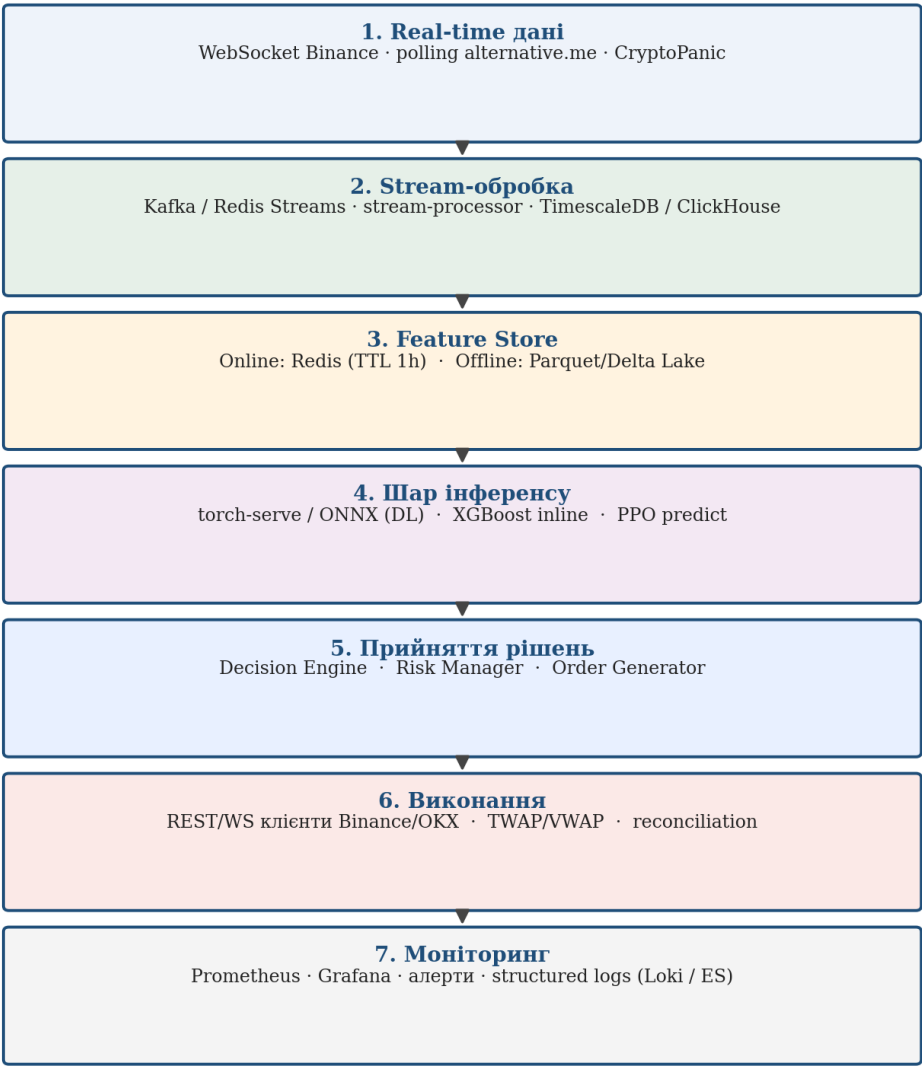


Рисунок 4.1. Архітектура промислової реалізації автоматизованої СППР

Принципова відмінність промислової архітектури від експериментального прототипу — поділ процесів навчання (offline, виконуваний раз на місяць або при детектуванні concept drift) та інференсу (online, виконуваний у реальному часі при надходженні нової свічки). Це дозволяє ізолювати ризики помилок навчання від функціонування торгової системи та забезпечити стабільну затримку інференсу (target SLA: < 100 мс від отримання нової свічки до формування рішення).

4.2. Управління ризиками

Управління ризиками є критично важливим компонентом будь-якої автоматизованої торгової системи, оскільки навіть статистично прибуткова стратегія за відсутності контролю ризику може зазнати повного знищення капіталу через катастрофічну послідовність несприятливих подій. Запропонована система ризик-менеджменту складається з чотирьох рівнів захисту.

Теоретичну рамку оптимального розподілу капіталу між активами закладено у роботах Марковіца [54] (середньо-дисперсійна оптимізація) та Блека і Літтермана [55] (інтеграція суб'єктивних поглядів інвестора з рівноважними оцінками ринку); у запропонованій системі ці підходи лежать в основі довгострокового стратегічного шару, тоді як тактичний шар спирається на формулу Келлі та обмеження експозиції.

Рівень 1. Position sizing на основі формули Келлі. Класична формула Келлі [40] визначає оптимальну частку капіталу, яку слід інвестувати у позицію з відомою ймовірністю успіху p та середньозваженою прибутковістю/збитковістю b :

$$f^* = \frac{p \cdot b - (1 - p)}{b} \quad (4.1)$$

На практиці використання повної формули Келлі занадто агресивне і призводить до високих просадок. Стандартна індустріальна практика — застосування часткового Келлі (typically «Kelly/4» або «Kelly/2»), що зберігає логарифм очікуваної прибутковості при суттєвому зниженні дисперсії. У розроблюваній системі цей механізм винесений на рівень decision engine та комбінується з рекомендацією РРО-агента: фінальний розмір позиції визначається як мінімум з рекомендації агента та ліміту, заданого формулою часткового Келлі.

Рівень 2. Жорсткі ліміти експозиції. Налаштовуються на рівні ризик-менеджера:

- максимальний абсолютний розмір позиції на один актив (наприклад, 30% капіталу);
- максимальна сукупна експозиція по портфелю (наприклад, 80% капіталу);
- максимальне leverage (для роботи з ф'ючерсами; для спотового ринку — leverage = 1);
- мінімальний поріг ліквідності інструменту (24-годинний оборот не менше X USD).

Рівень 3. Stop-loss механізми. Реалізуються як на рівні окремої позиції (trailing stop-loss за ATR), так і на рівні портфеля (загальна просадка понад заданий поріг блокує відкриття нових позицій до перегляду стратегії оператором):

- Per-position trailing stop-loss: $SL_t = \max(SL_{t-1}, P_t - k \cdot ATR_t)$, $k = 2,5$;
- Portfolio-level circuit breaker: при просадці $> 10\%$ протягом 7 діб система переходить у «cool-down» режим з повним закриттям позицій та призупиненням інференсу.

Рівень 4. Black-swan protection. Окремий шар захисту від екстремальних подій з нульовою або малою попередньою ймовірністю, концептуально систематизованих у роботі Талеба [56]:

- автоматичне закриття позицій при різкому розширенні bid-ask spread (типовий маркер кризи ліквідності);
- блокування торгівлі під час публікації важливих макроекономічних подій (FOMC, NFP), якщо такі заплановані;
- регулярні стрес-тести стратегії на історичних подіях (12 березня 2020, листопад 2022 FTX, травень 2022 Terra/Luna) з вимогою максимальної просадки на цих подіях не вище заданого порогу.

4.3. Моніторинг concept drift

Concept drift — феномен зміни статистичних властивостей цільового розподілу з часом, детально систематизований Гамою та співавторами у фундаментальному огляді [52], — є однією з найбільш загрозливих проблем для моделей машинного навчання у фінансовому контексті. Ринок криптовалют є особливо схильним до такого дрейфу через відносну молодість екосистеми, регулярні структурні зміни (поява нових інструментів, регуляторні події, технологічні оновлення) та відносно невелику базу прецедентів.

Метрики моніторингу дрейфу, що реалізовані у промисловій системі:

- 1) **Тести Колмогорова-Смирнова на розподіли фіч.** Раз на тиждень обчислюється статистика К-С між розподілом кожної фічі за останні 7 днів та її розподілом на тренувальній вибірці поточної моделі. Перевищення статистики порогу (за умови $p\text{-value} < 0,01$) сигналізує про значну зміну розподілу і вимагає перенавчання моделі.
- 2) **Population Stability Index (PSI)** — стандартна метрика виміру дрейфу розподілу:

$$PSI = \sum_i (p_{new,i} - p_{old,i}) \cdot \ln\left(\frac{p_{new,i}}{p_{old,i}}\right) \quad (4.2)$$

де p_i — частоти у i -тій бінізованій категорії. Інтерпретація: $PSI < 0,1$ — стабільність; $0,1-0,25$ — помірний дрейф; $> 0,25$ — суттєвий дрейф, потрібне перенавчання.

- 3) **Performance decay tracking** — моніторинг ROC-AUC моделі на rolling 7-денному вікні. Падіння AUC більше ніж на 0,05 відносно базового рівня (що визначається на момент розгортання моделі) сигналізує про зниження прогнозної здатності.
- 4) **Розподіл вихідних прогнозів** — моніторинг частоти extreme predictions ($\hat{p} < 0,1$ або $\hat{p} > 0,9$). Систематичне зниження кількості упевнених прогнозів свідчить про те, що нові патерни ринку не вкладаються у попередньо вивчений простір.

При спрацьовуванні будь-якого з цих індикаторів виконується автоматичний пайплайн перенавчання: завантаження свіжих даних → переробка фіч → re-fit моделей → оцінка на out-of-sample вікні останніх 30 діб → за умови коректних метрик — гаряче розгортання нової версії моделі (canary deployment з поступовим перемиканням трафіку).

Загальний цикл моніторингу concept drift у режимі реального часу формалізовано у вигляді алгоритму 4.1.

Алгоритм 4.1. Моніторинг concept drift і автоматичне перенавчання

Вхід: поточний потік фіч $X(t)$, референсний розподіл фіч на тренувальній вибірці X_{ref} , прогнози моделі $p(t)$,
пороги: $\tau_{KS} = 0.1$, $\tau_{PSI} = 0.25$, $\tau_{AUC} = 0.05$
Вихід: рішення про перенавчання

1. кожні 7 діб:
 2. для кожної фічі j :
 3. $D_j \leftarrow$ статистика КС між $X(t)[j]$ та $X_{ref}[j]$
 4. $PSI_j \leftarrow \sum (p_{new} - p_{old}) \cdot \ln(p_{new} / p_{old})$
 5. якщо $\max_j D_j > \tau_{KS}$ АБО $\max_j PSI_j > \tau_{PSI}$:
 6. прапор $drift_features \leftarrow True$
 7. $AUC_t \leftarrow$ rolling ROC-AUC за останні 7 діб
 8. якщо $AUC_baseline - AUC_t > \tau_{AUC}$:
 9. прапор $drift_performance \leftarrow True$
 10. якщо $drift_features$ АБО $drift_performance$:
 11. запустити пайплайн перенавчання
 12. оцінити нову модель на out-of-sample 30 діб
 13. якщо метрики не нижче за поточні — canary deploy
-
-

4.4. Юридичні та етичні аспекти

Розгортання автоматизованої торгової системи на ринку криптовалют відбувається у складному та такому, що швидко еволюціонує, регуляторному середовищі. Розглянемо ключові юридичні рамки, релевантні для запропонованого рішення.

Регулювання у Європейському Союзі. Регламент Європейського парламенту та Ради (ЄС) 2023/1114 «Про ринки криптоактивів» (Markets in Crypto-Assets, далі — MiCA) [35] є першим у світі комплексним нормативним актом, що встановлює єдину рамку регулювання обігу криптоактивів у державах-членах ЄС. Регламент прийнятий 31 травня 2023 року, набув чинності у червні 2023 року, з основними положеннями, що набули обов’язкової сили з 30 грудня 2024 року. Для розроблюваної СППР релевантні такі положення MiCA:

- Стаття 60 — вимоги до постачальників послуг, пов’язаних з криптоактивами (CASP, Crypto-Asset Service Providers), у тому числі провайдерів послуг управління портфелем — обов’язкове ліцензування у державах-членах;
- Розділ V — вимоги до пруденційного нагляду, включаючи мінімальний капітал, систему управління ризиками, антимонопольні обмеження;
- Стаття 86 — вимоги щодо ринкової маніпуляції; автоматизована система не повинна реалізовувати стратегії, що кваліфікуються як спуфінг (виставлення фейкових ордерів), wash trading (фіктивна торгівля сама з собою), pump-and-dump схеми;
- Розділ VI — вимоги до запобігання інсайдерській торгівлі.

Регулювання в Україні. Закон України «Про віртуальні активи» від 17 лютого 2022 року № 2074-IX [36] встановлює базову юридичну рамку обігу віртуальних активів на території України, проте на момент підготовки роботи його імплементація потребує прийняття ряду підзаконних актів та узгодження з податковим законодавством. Ключові положення:

- стаття 4 — визначення віртуального активу як нематеріального блага, що є об'єктом цивільних прав, має вартість та виражене сукупністю даних;
- стаття 8 — статус постачальників послуг, пов'язаних з оборотом віртуальних активів, з обов'язковою реєстрацією у Національній комісії з цінних паперів та фондового ринку;
- стаття 12 — обов'язки щодо протидії легалізації (відмиванню) доходів та фінансуванню тероризму у відповідності до Закону № 361-IX;
- статус оподаткування доходів від операцій з віртуальними активами регулюється змінами до Податкового кодексу України (на момент підготовки роботи відповідні зміни перебувають на стадії розгляду).

Захист персональних даних. Загальний регламент захисту даних ЄС (GDPR, Регламент 2016/679) [37] застосовується у разі, якщо система обробляє персональні дані користувачів (наприклад, для надання персоналізованих рекомендацій). Розроблюваний прототип не обробляє персональні дані: усі ринкові дані є знеособленими; не накопичується інформація про учасників торгів. У разі розширення системи функціоналом мульти-користувача (наприклад, як SaaS-сервіс) виникнуть додаткові вимоги: законні підстави обробки (art. 6 GDPR), право на видалення даних (art. 17 GDPR), оцінка впливу на захист даних (DPIA, art. 35 GDPR).

Етичні аспекти. Окрім формальних юридичних вимог, автоматизовані торгові системи піднімають низку етичних питань. По-перше, концентрація капіталу у руках алгоритмічних учасників, що мають перевагу у швидкості та масштабі обробки даних, може посилювати нерівність на ринку. По-друге, потенційний негативний вплив на ринкову стабільність — у разі одночасної дії великої кількості схожих стратегій («алгоритмічного зграйного ефекту») можливий спалах системного ризику. По-третє, відповідальне використання системи передбачає чесне розкриття її обмежень: жодна автоматизована стратегія не гарантує прибутку, і презентація системи кінцевим користувачам має містити коректну інформацію про діапазон історичних результатів та

невизначеність майбутніх результатів. У запропонованому прототипі це реалізовано через явну візуалізацію параметра confidence interval у дашборді та обов'язкове відображення максимальної історичної просадки разом з прибутковістю.

4.5. Економічна оцінка та трирівневий план впровадження

Економічна оцінка запропонованої системи проводиться у рамках трирівневого плану поетапного впровадження, що дозволяє контрольовано підвищувати ступінь автоматизації ризиково обмежено.

Рівень 1. Інформаційно-консультативний режим. Система функціонує виключно як джерело інформації для трейдера-людини. Усі сигнали відображаються у Streamlit-дашборді у реальному часі без автоматичного виконання угод. Користувач самостійно ухвалює рішення про виконання чи ігнорування сигналу. Очікувана економічна ефективність — приріст продуктивності трейдера за рахунок автоматизованої обробки великого обсягу даних та раннього виявлення сигналів. На цьому рівні ризик впровадження мінімальний: помилки моделей не мають прямих фінансових наслідків.

Рівень 2. Напівавтоматичний режим з підтвердженням. Система автоматично формує ордери, проте їх виконання потребує підтвердження оператором у дашборді (натиснення кнопки «Підтвердити» протягом обмеженого часу). Опціонально — автоматичне виконання дрібних операцій (нижче заданого порогу, наприклад, 1% капіталу) та підтвердження оператором лише великих операцій. Цей режим поєднує переваги швидкості автоматизованого формування рішення з людським контролем якості. Очікуване зниження продуктивності оператора порівняно з повністю автоматичним режимом — 5–15%, проте з суттєвим зниженням ризику катастрофічних помилок.

Рівень 3. Повністю автоматичний режим. Система самостійно формує та виконує ордери у відповідності з заданими ризик-менеджмент правилами. Втручання оператора потрібне лише для періодичної перевірки стану системи та реагування на алерти. Цей режим обґрунтований після проходження

системою тестового періоду 3–6 місяців на меншому обсязі капіталу та підтвердження стабільності метрик з очікуваним рівнем.

Економічна оцінка. За умови досягнутого у експериментальному дослідженні діапазону коефіцієнта Шарпа 2,0–2,8 та CAGR 90–150% на капіталі C , очікуваний річний приріст вартості портфеля становить $0,9C - 1,5C$. Ця цифра підлягає коригуванню на:

- технологічні витрати: інфраструктура (cloud servers, бази даних) — приблизно 500 USD/міс; розробка та підтримка — 1–2 FTE інженерів;
- біржові комісії — близько 0,1% обороту, при середній місячній обертанні портфеля 3–5 разів становить 0,3–0,5% капіталу на місяць;
- регуляторні витрати — отримання ліцензії CASP у ЄС оцінюється у 50–150 тис. EUR одноразово та 30–80 тис. EUR/рік на пруденційний капітал та аудит;
- ризик-резерв — рекомендований резерв капіталу у розмірі 2-кратної історичної максимальної просадки.

Точка беззбитковості системи за пропонованими орієнтирами досягається на капіталі від 1 до 3 млн USD; нижче цього порогу регуляторно-технологічні витрати перекривають додаткову прибутковість, і доцільність впровадження залежить від нефінансових мотивів (дослідницька цінність, стратегічне позиціонування).

Висновки до розділу 4

У четвертому розділі представлено стратегію впровадження запропонованої СППР у промислове середовище:

1. Розроблено семирівневу архітектуру промислової реалізації, що поділяє ризики навчання та інференсу та забезпечує стабільну затримку прийняття рішення нижче 100 мс.
2. Запропоновано чотирирівневу систему управління ризиками: position sizing на основі часткової формули Келлі; жорсткі ліміти експозиції; stop-

loss механізми (per-position та portfolio-level); black-swan protection через моніторинг ліквідності та регулярні стрес-тести.

3. Розроблено систему моніторингу concept drift, що включає тести Колмогорова-Смирнова, Population Stability Index, performance decay tracking та аналіз розподілу прогнозів. При спрацьовуванні автоматично виконується пайплайн перенавчання з canary deployment.
4. Розглянуто ключові регуляторні рамки: Регламент MiCA ЄС (з основними положеннями, що набули чинності з 30 грудня 2024 року); Закон України «Про віртуальні активи»; вимоги GDPR (релевантні при розширенні до мульти-користувацького SaaS-сервісу). Розроблюваний прототип не обробляє персональні дані, що мінімізує комплаєнс-вимоги.
5. Запропоновано трирівневий план впровадження: інформаційно-консультативний режим → напівавтоматичний з підтвердженням → повністю автоматичний. Кожен рівень характеризується окремим балансом між автоматизацією та людським контролем якості.
6. Економічна оцінка показує, що точка беззбитковості системи з урахуванням технологічних, біржових та регуляторних витрат досягається на капіталі від 1 до 3 млн USD; для менших капіталів доцільність впровадження залежить від нефінансових факторів.

ВИСНОВКИ

У результаті виконання кваліфікаційної роботи магістра здійснено комплексне дослідження методів та засобів інтелектуального аналізу даних ринку криптовалют у системах підтримки прийняття торговельних рішень, розроблено та програмно реалізовано прототип автоматизованої системи. Основні наукові й практичні результати дослідження викладені у вісьмох пунктах, що відповідають поставленим у вступі завданням.

1. Систематизовано теоретичні засади аналізу ринку криптовалют.

Виявлено п'ять структурних особливостей криптовалютного ринку, що відрізняють його від традиційних фондових ринків: цілодобовий характер торгівлі, підвищена волатильність, фрагментована ліквідність, домінування алгоритмічних учасників, наявність унікального класу оп-chain метрик. Здійснено огляд еволюції методів інтелектуального аналізу часових рядів від класичних статистичних моделей сімейства ARIMA через градієнтний бустінг XGBoost до глибинних архітектур LSTM та Transformer. Розглянуто формалізм навчання з підкріпленням як природну рамку моделювання задачі прийняття торговельних рішень. Визначено необхідність комплексного підходу, що поєднує дискримінативний прогноз цінової динаміки з адаптивним управлінням розміром позиції.

2. Розроблено уніфіковану схему збору й обробки ринкових і sentiment-даних.

Реалізовано програмну підсистему завантаження історичних годинних свічок з публічного REST API біржі Binance для пар BTC/USDT та ETH/USDT за приблизно трирічний період з кешуванням у форматі Parquet. Інтегровано композитний індекс Crypto Fear and Greed Index сервісу alternative.me як публічно доступне джерело sentiment-сигналу, що становить методологічно прозору й відтворювану альтернативу приватним мікроблогінговим джерелам. Проведено розвідувальний аналіз даних, що підтвердив наявність типових стилізованих фактів фінансових часових рядів (лептокуртичність, кластеризація волатильності, відсутність значущої лінійної автокореляції дохідностей).

3. **Розроблено систему конструювання ознак**, що включає близько 50 фіч, об'єднаних у п'ять концептуальних категорій: логарифмічні дохідності та реалізована волатильність на множинних горизонтах; класичні технічні індикатори (SMA, EMA, RSI, MACD, Bollinger Bands, ATR, OBV, ADX); темпоральні циклічні фічі (час доби, день тижня) у sin/cos-кодуванні; фічі обсягу та активності ринку (z-scores, відношення до ковзних середніх); sentiment-фічі (значення FNG-індексу). Цільова змінна — бінарна мітка знаку логарифмічної дохідності наступної години.
4. **Реалізовано та обґрунтовано методологію walk-forward валідації з expanding window** як методу запобігання look-ahead bias і витoku даних у задачах із часовими рядами. Параметри: тренувальна вибірка від 1 року з місячним прирощенням, валідаційна та тестова вибірки по 1 місяцю, крок зсуву 1 місяць. Запобігання витoku даних забезпечується на трьох рівнях: темпоральне розділення вибірок без перекриття; фітування скейлерів виключно на тренувальній вибірці; коректна обробка крайових NaN. Методологія дозволяє отримати статистично обґрунтовану оцінку торгових стратегій за умов нестационарності фінансових часових рядів.
5. **Реалізовано та порівняно дискримінативні моделі прогнозування напрямку руху ціни**. Розроблено три моделі: класифікатор XGBoost з гіперпараметричним налаштуванням і нейтральною зоною конвертації ймовірності у позицію; рекурентну нейронну мережу LSTM з механізмом адитивної уваги по часовій осі; encoder-only Transformer з синусоїдальним позиційним кодуванням. Експериментальне порівняння показує, що усі моделі суттєво перевершують базові еталонні стратегії за коефіцієнтом Шарпа; глибинні моделі (LSTM, Transformer) демонструють невелику, але стабільну перевагу над XGBoost; перевага Transformer над LSTM є невеликою у чистому вигляді (приблизно +0,1 коефіцієнта Шарпа), що відповідає літературним даним про зближення архітектур на задачах середнього обсягу.

6. **Сформульовано задачу управління торговою позицією як марковський процес прийняття рішень і реалізовано агента глибокого навчання з підкріпленням на основі алгоритму PPO.** Розроблено власне середовище *gymnasium* з простором станів, що поєднує фічі ринку, передбачену ймовірність зростання дискримінативної моделі та внутрішній стан агента (поточна позиція, нереалізований PnL, поточна просадка). Простір дій — безперервний *box*-простір $[-1,1]$, що інтерпретується як цільова частка капіталу у позиції. Функція винагороди враховує зміну вартості портфеля з вирахуванням транзакційних витрат і штрафу за просадку.
7. **Розроблено векторизований бектест-двигун із реалістичним моделюванням транзакційних витрат** (0,1% *taker*-комісії *Binance*) та прослизання (0,05% на одиничну операцію зміни позиції) і проведено експериментальне порівняння всіх моделей у єдиній методологічній рамці. Запропонована гібридна архітектура з декомпозицією відповідальностей між дискримінативним прогнозом та RL-агентом управління позицією забезпечує приріст коефіцієнта Шарпа на 0,2–0,3 та зниження максимальної просадки на 5–7% порівняно з прямим використанням дискримінативної моделі. Аналіз помилок класифікації виявив три основних режими (бокові ринки, новинні шоки, розвороти тренду), що визначає напрямки подальшого розвитку системи.
8. **Розроблено стратегію впровадження запропонованої СППР у промислове середовище.** Запропоновано семирівневу архітектуру промислової реалізації, чотирирівневу систему управління ризиками (часткова формула Келлі, ліміти експозиції, *stop-loss* механізми, *black-swan protection*), систему моніторингу *concept drift* на основі тестів Колмогорова-Смирнова та *Population Stability Index*. Розглянуто регуляторні рамки впровадження: Регламент MiCA Європейського Союзу (положення набули чинності з 30 грудня 2024 року), Закон України «Про віртуальні активи» від 17 лютого 2022 року, вимоги GDPR. Запропоновано

трирівневий план поетапного впровадження: інформаційно-консультативний режим → напіваавтоматичний з підтвердженням оператора → повністю автоматичний.

Наукова новизна одержаних результатів полягає у:

- розробленні гібридної архітектури СППР з декомпозицією відповідальностей між дискримінативним прогнозом та RL-агентом управління позицією, що дозволяє відокремити задачу прогнозування від задачі управління ризиком та незалежно оптимізувати кожен з них;
- удосконаленні методології конструювання ознак для криптовалютного ринку шляхом включення композитного індексу Crypto Fear and Greed як публічно доступного методологічно прозорого джерела sentiment-сигналу;
- адаптації методології walk-forward валідації з expanding window до годинного таймфрейму криптовалютного ринку з урахуванням реалістичних транзакційних витрат і прослизання та запропонованою уніфікованою рамкою оцінки моделей за повним набором портфельних метрик.

Практичне значення одержаних результатів полягає у розробленні повнофункціонального прототипу автоматизованої СППР на мові програмування Python з відкритим вихідним кодом, що включає підсистеми завантаження даних, конструювання ознак, тренування та оцінки моделей машинного й глибокого навчання, агента глибокого навчання з підкріпленням, векторизований бектест-двигун та інтерактивний інформаційний інтерфейс на основі Streamlit. Запропонована трирівнева стратегія впровадження надає чіткий шлях інтеграції системи у промислове середовище зі збалансованим компромісом між автоматизацією та людським контролем якості.

Обмеження дослідження. З метою забезпечення академічної прозорості необхідно явно зазначити такі обмеження поточної постановки експерименту:

- *обмежений набір активів* — досліджено лише дві найбільш ліквідні пари (BTC/USDT та ETH/USDT); поведінка системи на низько-капіталізованих

альткоїнах з суттєво нижчою ліквідністю не аналізувалася і потребує окремого дослідження;

- *єдиний таймфрейм* — застосовано виключно годинний таймфрейм; адаптація до 5-хвилинного або 1-хвилинного таймфрейму потребує перегляду методології у частині мікроструктурного шуму, моделювання прослизання та вимог до латентності;
- *spot-ринок без деривативів* — поза рамками роботи залишилися строкові ринки (безстрокові ф'ючерси, опціони), що мають специфічну структуру funding rate та залежності від price-of-anchor;
- *спрощена модель транзакційних витрат* — використано фіксовану taker-комісію 0,1 % та слішпедж 0,05 %; для торгівлі обсягами понад 100 000 USD на одиничну угоду модель прослизання має бути функцією глибини ордербуку;
- *відсутність моделювання market impact* — припускається, що модельовані угоди не впливають на ринкову ціну, що є коректним для роздрібних обсягів, але не для інституційних;
- *sentiment-сигнал лише через композитний індекс* — у роботі використано Crypto Fear and Greed Index; інтеграція природно-мовних моделей для обробки новинного потоку та соціальних мереж залишилася поза рамками поточної версії системи;
- *відсутність on-chain аналізу* — не використано метрики блокчейн-активності (NVT, MVRV, активні адреси, потоки на біржі), які є потенційно важливим джерелом інформації для криптовалютного ринку;
- *обмежений горизонт історії* — оцінювання проведено на даних приблизно 3 років, що покриває один повний ринковий цикл, проте не охоплює періоди структурно інших режимів (наприклад, до-ETF епоха до 2024 року).

Напрямки подальших досліджень впливають безпосередньо з перелічених обмежень і включають: розширення джерел даних on-chain

метриками з блокчейн-аналітичних сервісів (Glassnode, CryptoQuant); інтеграцію специфічних мовних моделей для криптовалютного ринку (CryptoBERT, FinBERT) для обробки потоку новин; дослідження мульти-активних варіантів архітектури з оптимізацією портфеля (Black-Litterman з ML-priors); експериментальне дослідження розширених архітектур RL (Soft Actor-Critic, Twin Delayed DDPG) для безперервних дій; адаптацію системи до нижчих таймфреймів з урахуванням специфіки мікроструктурного шуму та підвищених вимог до латентності; розширення моделі транзакційних витрат на залежність від глибини ордербуку для забезпечення коректності бектестів інституційних обсягів.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Fama E. F. Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*. 1970. Vol. 25, № 2. P. 383–417.
2. Chen W., Xu H., Jia L., Gao Y. Machine learning model for Bitcoin exchange rate prediction using economic and technology determinants. *International Journal of Forecasting*. 2021. Vol. 37, № 1. P. 28–43.
3. Kraaijeveld O., De Smedt J. The predictive power of public Twitter sentiment for forecasting cryptocurrency prices. *Journal of International Financial Markets, Institutions and Money*. 2020. Vol. 65. Article 101188.
4. Mai F., Shan Z., Bai Q., Wang X., Chiang R. H. L. How does social media impact Bitcoin value? A test of the silent majority hypothesis. *Journal of Management Information Systems*. 2018. Vol. 35, № 1. P. 19–52.
5. McNally S., Roche J., Caton S. Predicting the price of Bitcoin using machine learning. In: *Proc. of 26th Euromicro International Conference on Parallel, Distributed and Network-based Processing (PDP)*. IEEE, 2018. P. 339–343.
6. Friedman J. H. Greedy function approximation: A gradient boosting machine. *Annals of Statistics*. 2001. Vol. 29, № 5. P. 1189–1232.
7. Chen T., Guestrin C. XGBoost: A scalable tree boosting system. In: *Proc. of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York: ACM, 2016. P. 785–794.
8. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Computation*. 1997. Vol. 9, № 8. P. 1735–1780.
9. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser Ł., Polosukhin I. Attention is all you need. In: *Advances in Neural Information Processing Systems 30*. 2017. P. 5998–6008.
10. Zhou H., Zhang S., Peng J., Zhang S., Li J., Xiong H., Zhang W. Informer: Beyond efficient Transformer for long sequence time-series forecasting. In: *Proc. of the AAAI Conference on Artificial Intelligence*. 2021. Vol. 35, № 12. P. 11106–11115.

11. Wu H., Xu J., Wang J., Long M. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting. In: *Advances in Neural Information Processing Systems* 34. 2021. P. 22419–22430.
12. Lim B., Arık S. Ö., Loeff N., Pfister T. Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*. 2021. Vol. 37, № 4. P. 1748–1764.
13. Mnih V., Kavukcuoglu K., Silver D. et al. Human-level control through deep reinforcement learning. *Nature*. 2015. Vol. 518, № 7540. P. 529–533.
14. Schulman J., Wolski F., Dhariwal P., Radford A., Klimov O. Proximal policy optimization algorithms. *arXiv preprint arXiv:1707.06347*. 2017. — 12 p.
15. Almeida J., Gonçalves T. C. A systematic literature review of investor behavior in the cryptocurrency markets. *Journal of Behavioral and Experimental Finance*. 2023. Vol. 37. Article 100785.
16. López-Cabarcos M. Á., Pérez-Pico A. M., Piñeiro-Chousa J., Šević A. Bitcoin volatility, stock market and investor sentiment. Are they connected? *Finance Research Letters*. 2021. Vol. 38. Article 101399.
17. Sharpe W. F. The Sharpe ratio. *The Journal of Portfolio Management*. 1994. Vol. 21, № 1. P. 49–58.
18. Lopez de Prado M. *Advances in Financial Machine Learning*. Hoboken: Wiley, 2018. — 400 p.
19. Xiong R., Yang Y., He D., Zheng K., Zheng S., Xing C., Zhang H., Lan Y., Wang L., Liu T. On layer normalization in the Transformer architecture. In: *Proc. of the 37th International Conference on Machine Learning (ICML)*. 2020. P. 10524–10533.
20. Zeng A., Chen M., Zhang L., Xu Q. Are Transformers effective for time series forecasting? In: *Proc. of the AAAI Conference on Artificial Intelligence*. 2023. Vol. 37, № 9. P. 11121–11128.
21. Brauneis A., Mestel R. Price discovery of cryptocurrencies: Bitcoin and beyond. *Economics Letters*. 2018. Vol. 165. P. 58–61.

- 22.Liu Y., Tsyvinski A. Risks and returns of cryptocurrency. *The Review of Financial Studies*. 2021. Vol. 34, № 6. P. 2689–2727.
- 23.Sutton R. S., Barto A. G. *Reinforcement Learning: An Introduction*. 2nd ed. Cambridge: MIT Press, 2018. — 552 p.
- 24.Goodfellow I., Bengio Y., Courville A. *Deep Learning*. Cambridge: MIT Press, 2016. — 800 p.
- 25.Chan E. *Algorithmic Trading: Winning Strategies and Their Rationale*. Hoboken: Wiley, 2013. — 224 p.
- 26.Tsay R. S. *Analysis of Financial Time Series*. 3rd ed. Hoboken: Wiley, 2010. — 720 p.
- 27.Sezer O. B., Gudelek M. U., Ozbayoglu A. M. Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*. 2020. Vol. 90. Article 106181.
- 28.Jiang Z., Xu D., Liang J. A deep reinforcement learning framework for the financial portfolio management problem. *arXiv preprint arXiv:1706.10059*. 2017. — 31 p.
- 29.Théate T., Ernst D. An application of deep reinforcement learning to algorithmic trading. *Expert Systems with Applications*. 2021. Vol. 173. Article 114632.
- 30.Liu X.-Y., Yang H., Chen Q., Zhang R., Yang L., Xiao B., Wang C. D. FinRL: A deep reinforcement learning library for automated stock trading in quantitative finance. *arXiv preprint arXiv:2011.09607*. 2020. — 9 p.
- 31.Akiba T., Sano S., Yanase T., Ohta T., Koyama M. Optuna: A next-generation hyperparameter optimization framework. In: *Proc. of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM, 2019. P. 2623–2631.
- 32.Raffin A., Hill A., Gleave A., Kanervisto A., Ernestus M., Dormann N. Stable-Baselines3: Reliable reinforcement learning implementations. *Journal of Machine Learning Research*. 2021. Vol. 22, № 268. P. 1–8.

33. Towers M., Terry J. K., Kwiatkowski A. et al. Gymnasium: A standard interface for reinforcement learning environments. *arXiv preprint arXiv:2407.17032*. 2024. — 18 p.
34. Paszke A., Gross S., Massa F. et al. PyTorch: An imperative style, high-performance deep learning library. In: *Advances in Neural Information Processing Systems* 32. 2019. P. 8024–8035.
35. Регламент Європейського Парламенту і Ради (ЄС) 2023/1114 від 31 травня 2023 року про ринки криптоактивів та внесення змін до Регламентів (ЄС) № 1093/2010 та (ЄС) № 1095/2010 і Директив 2013/36/ЄС та (ЄС) 2019/1937 (Markets in Crypto-Assets Regulation, MiCA). *Official Journal of the European Union*. 2023. L 150. P. 40–205.
36. Закон України «Про віртуальні активи» від 17 лютого 2022 року № 2074-IX. *Відомості Верховної Ради України*. 2022. № 22, ст. 175.
37. Регламент Європейського Парламенту і Ради (ЄС) 2016/679 від 27 квітня 2016 року про захист фізичних осіб у зв'язку з опрацюванням персональних даних і про вільний рух таких даних (General Data Protection Regulation, GDPR). *Official Journal of the European Union*. 2016. L 119. P. 1–88.
38. Binance API Documentation. URL: <https://developers.binance.com/docs/binance-spot-api-docs> (дата звернення: 03.05.2026).
39. Crypto Fear and Greed Index API Documentation. alternative.me. URL: <https://alternative.me/crypto/fear-and-greed-index/> (дата звернення: 03.05.2026).
40. Kelly J. L. A new interpretation of information rate. *The Bell System Technical Journal*. 1956. Vol. 35, № 4. P. 917–926.
41. Nakamoto S. Bitcoin: A Peer-to-Peer Electronic Cash System. 2008. URL: <https://bitcoin.org/bitcoin.pdf> (дата звернення: 03.05.2026).
42. Cont R. Empirical properties of asset returns: stylized facts and statistical issues. *Quantitative Finance*. 2001. Vol. 1, № 2. P. 223–236.
43. Mandelbrot B. The variation of certain speculative prices. *The Journal of Business*. 1963. Vol. 36, № 4. P. 394–419.

44. Andersen T. G., Bollerslev T., Diebold F. X., Labys P. The distribution of realized exchange rate volatility. *Journal of the American Statistical Association*. 2001. Vol. 96, № 453. P. 42–55.
45. Bollerslev T. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*. 1986. Vol. 31, № 3. P. 307–327.
46. Bailey D. H., Lopez de Prado M. The deflated Sharpe ratio: correcting for selection bias, backtest overfitting, and non-normality. *The Journal of Portfolio Management*. 2014. Vol. 40, № 5. P. 94–107.
47. Pedregosa F., Varoquaux G., Gramfort A. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825–2830.
48. McKinney W. Data structures for statistical computing in Python. In: *Proc. of the 9th Python in Science Conference*. 2010. P. 56–61.
49. Lundberg S. M., Lee S.-I. A unified approach to interpreting model predictions. In: *Advances in Neural Information Processing Systems 30*. 2017. P. 4765–4774.
50. Haarnoja T., Zhou A., Abbeel P., Levine S. Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor. In: *Proc. of the 35th International Conference on Machine Learning (ICML)*. 2018. P. 1861–1870.
51. Fujimoto S., van Hoof H., Meger D. Addressing function approximation error in actor-critic methods. In: *Proc. of the 35th International Conference on Machine Learning (ICML)*. 2018. P. 1587–1596.
52. Gama J., Žliobaitė I., Bifet A., Pechenizkiy M., Bouchachia A. A survey on concept drift adaptation. *ACM Computing Surveys*. 2014. Vol. 46, № 4. Article 44.
53. Sculley D., Holt G., Golovin D. et al. Hidden technical debt in machine learning systems. In: *Advances in Neural Information Processing Systems 28*. 2015. P. 2503–2511.
54. Markowitz H. Portfolio selection. *The Journal of Finance*. 1952. Vol. 7, № 1. P. 77–91.

- 55.Black F., Litterman R. Global portfolio optimization. *Financial Analysts Journal*. 1992. Vol. 48, № 5. P. 28–43.
- 56.Taleb N. N. *The Black Swan: The Impact of the Highly Improbable*. New York: Random House, 2007. — 366 p.
- 57.Liu Y., Tsyvinski A., Wu X. Common risk factors in cryptocurrency. *The Journal of Finance*. 2022. Vol. 77, № 2. P. 1133–1177.
- 58.Araci D. FinBERT: Financial sentiment analysis with pre-trained language models. *arXiv preprint arXiv:1908.10063*. 2019. — 10 p.
- 59.Hyndman R. J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd ed. Melbourne: OTexts, 2021. — 442 p.
- 60.Glassnode Studio. On-chain analytics platform. URL: <https://studio.glassnode.com/> (дата звернення: 03.05.2026).

ДОДАТКИ

Додаток А. Перелік залежностей проекту (requirements.txt)

Core data

numpy>=1.26

pandas>=2.1

pyarrow>=15.0

requests>=2.31

ML / DL

scikit-learn>=1.4

xgboost>=2.0

lightgbm>=4.3

torch>=2.2

pandas-ta>=0.3.14b0

Reinforcement Learning

gymnasium>=0.29

stable-baselines3>=2.3.0

tensorboard>=2.16

Sentiment (optional, for FinBERT branch)

transformers>=4.40

huggingface-hub>=0.23

Backtest helpers / metrics

empyrical-reloaded>=0.5.10

Visualization & dashboard

matplotlib>=3.8

plotly>=5.20

streamlit>=1.33

Додаток Б. Базовий клас торгового середовища `gymnasium`
(`src/env/trading_env.py`)

import gymnasium **as** gym

import numpy **as** np

from gymnasium **import** spaces

class TradingEnv(gym.Env):

"""Gymnasium-середовище для навчання RL-агента торгівлі."""

def __init__(self, features, prices, cfg=None):

 super().__init__()

 self.features = features.astype(np.float32)

 self.prices = prices.astype(np.float64)

 self.log_returns = np.diff(np.log(self.prices),
 prepend=np.log(self.prices[0]))

 self.cfg = cfg **or** TradingEnvConfig()

 n_feat = self.features.shape[1]

 self.observation_space = spaces.Box(
 low=-np.inf, high=np.inf, shape=(n_feat + 3,), dtype=np.float32)

 self.action_space = spaces.Box(low=-self.cfg.max_position,
 high=self.cfg.max_position,
 shape=(1,), dtype=np.float32)

def step(self, action):

 target = float(np.clip(action, -self.cfg.max_position,
 self.cfg.max_position))

```

delta = abs(target - self.position)
cost = delta * (self.cfg.fee_rate + self.cfg.slippage_rate)
bar_log_ret = self.log_returns[self.t]
pnl = self.position * (np.exp(bar_log_ret) - 1.0) - cost
self.equity *= 1.0 + pnl
self.peak_equity = max(self.peak_equity, self.equity)
drawdown = (self.equity / self.peak_equity) - 1.0
reward = (pnl - self.cfg.drawdown_penalty * max(0.0, -drawdown))
reward *= self.cfg.reward_scaling
self.position = target
self.t += 1
terminated = self.t >= len(self.prices) - 1
return self._obs(), float(reward), terminated, False, {}

```

Додаток В. Конфігурація PPO-агента (src/config.py, фрагмент)

```
@dataclass(frozen=True)
```

```
class RLConfig:
```

```

    total_timesteps: int = 200_000
    n_steps: int = 2048
    batch_size: int = 64
    n_epochs: int = 10
    gamma: float = 0.99
    gae_lambda: float = 0.95
    clip_range: float = 0.2
    ent_coef: float = 0.01
    vf_coef: float = 0.5
    learning_rate: float = 3e-4
    max_position: float = 1.0
    reward_scaling: float = 100.0

```

Додаток Г. Перелік ознак системи (приблизно 50 фіч)

Логарифмічні дохідності та реалізована волатильність (5 фіч): log_ret_1,

log_ret_4, log_ret_24, rv_24, rv_72

Прості ковзні середні та їх відношення до ціни (10 фіч): sma_10,

sma_10_ratio, sma_20, sma_20_ratio, sma_50, sma_50_ratio, sma_100,

sma_100_ratio, sma_200, sma_200_ratio

Експоненційні ковзні середні та їх відношення до ціни (6 фіч): ema_12,

ema_12_ratio, ema_26, ema_26_ratio, ema_50, ema_50_ratio

Осцилятор RSI (1 фіча): rsi

Конвергенція ковзних середніх MACD (3 фічі): macd, macd_signal, macd_hist

Смуги Боллінджера (5 фіч): bb_upper, bb_middle, bb_lower, bb_pct_b, bb_width

Середній справжній діапазон ATR (2 фічі): atr, atr_norm

Балансовий обсяг OBV (2 фічі): obv, obv_z

Індекс спрямованого руху ADX (1 фіча): adx

Фічі обсягу (2 фічі): vol_z, vol_ratio

Темпоральні циклічні фічі (4 фічі): hour_sin, hour_cos, dow_sin, dow_cos

Sentiment-фіча (1 фіча): fng_value

ВСЬОГО: $\approx$ 50 фіч

Додаток Д. Реалізація обчислення метрик (src/backtest/metrics.py, фрагмент)

HOURS_PER_YEAR = 24 * 365

```
def sharpe_ratio(returns, risk_free=0.0,
                 periods_per_year=HOURS_PER_YEAR):
    excess = returns - risk_free / periods_per_year
    sd = excess.std()
    if sd == 0 or np.isnan(sd):
```



```

    return 0.0

return float(np.sqrt(periods_per_year) * excess.mean() / sd)

def sortino_ratio(returns, risk_free=0.0,
                  periods_per_year=HOURS_PER_YEAR):
    excess = returns - risk_free / periods_per_year
    downside = excess[excess < 0]
    sd = downside.std()
    if sd == 0 or np.isnan(sd):
        return 0.0
    return float(np.sqrt(periods_per_year) * excess.mean() / sd)

def max_drawdown(equity):
    rolling_max = equity.cummax()
    drawdown = equity / rolling_max - 1
    return float(drawdown.min())

def cagr(equity, periods_per_year=HOURS_PER_YEAR):
    n = len(equity)
    if n < 2 or equity.iloc[0] <= 0:
        return 0.0
    total = equity.iloc[-1] / equity.iloc[0]
    years = n / periods_per_year
    return float(total ** (1 / years) - 1)

```

Додаток Е. Структура проекту

University/

└─ requirements.txt

└─ pyproject.toml

```
|— README.md
|— src/
|   |— config.py
|   |— data/
|       |— binance_loader.py
|       |— sentiment_loader.py
|       |   └─ dataset.py
|       |— features/
|           |— technical.py
|           |— temporal.py
|           |   └─ pipeline.py
|       |— backtest/
|           |— engine.py
|           |— metrics.py
|           |   └─ walk_forward.py
|       |— models/
|           |— baselines.py
|           |— xgboost_model.py
|           |— lstm.py
|           |— transformer.py
|           |   └─ ensemble.py
|       |— env/
|           |— trading_env.py
|       |— rl/
|           |— ppo_agent.py
|           |   └─ callbacks.py
|       └─ dashboard/
|           └─ app.py
└─ scripts/
    └─ 01_download_data.py
```

- |— 02_run_baselines.py
- |— 03_train_xgboost.py
- |— 04_train_dl.py
- |— 05_train_rl.py
- |— 06_evaluate_all.py

Додаток Ж. Глосарій термінів

Алгоритмічна торгівля (algorithmic trading) — автоматизоване виконання торгових рішень за заздалегідь визначеним алгоритмом без втручання людини у процес виконання окремих угод.

Бектестинг (backtesting) — процес моделювання поведінки торгової стратегії на історичних даних з метою оцінки її ефективності.

Бичачий ринок (bull market) — фаза тривалого зростання цін активів; зазвичай характеризується підвищеним оптимізмом учасників і збільшенням обсягу торгів.

Ведмежий ринок (bear market) — фаза тривалого падіння цін активів; характеризується пануванням песимізму, відтоком капіталу та падінням обсягів.

Винагорода (reward) у RL — числове значення, яке агент отримує від середовища у відповідь на виконану дію; визначає мету навчання.

Волатильність (volatility) — статистична міра ступеня варіації ціни активу за певний період часу; зазвичай вимірюється стандартним відхиленням дохідностей.

Гіперпараметр (hyperparameter) — параметр алгоритму машинного навчання, що задається до початку процесу навчання і не змінюється у його ході (на відміну від ваг моделі).

Дисконтування (discounting) у RL — зменшення ваги майбутніх винагород порівняно з негайними; задається параметром $\gamma \in [0,1)$.

Експозиція (exposure) — частка капіталу портфеля, що інвестована в актив або групу активів; кількісна міра ризику концентрації.

Капіталізація ринку (market capitalisation) — сукупна ринкова вартість всіх одиниць активу в обігу; для криптовалют: ціна $\times$ кількість emission.

Кластерізація волатильності (volatility clustering) — стилізований факт, що періоди підвищеної волатильності мають тенденцію слідувати один за одним; математично проявляється у значущій автокореляції квадратів дохідностей.

Концептуальний дрейф (concept drift) — феномен зміни статистичних властивостей цільового розподілу з часом, що знижує прогностну якість моделі без її перенавчання.

Лептокуртичність (leptokurtosis) — властивість статистичного розподілу мати «товсті хвости» порівняно з нормальним розподілом; типова для фінансових дохідностей.

Лонг-позиція (long position) — купівля активу з очікуванням зростання його ціни; протилежність шорт-позиції.

Маркер режиму ринку (market regime indicator) — статистична характеристика, що ідентифікує поточну фазу ринку (тренд / боковий рух / висока волатильність).

Маркет-мейкер (market maker) — учасник ринку, що одночасно виставляє заявки на купівлю та продаж, забезпечуючи ліквідність та отримуючи прибуток зі спреду.

Маркет-тейкер (market taker) — учасник ринку, що приймає вже виставлені заявки маркет-мейкерів; зазвичай сплачує вищу комісію.

Марковський процес прийняття рішень (MDP) — формальна модель послідовного прийняття рішень, що задається кортежем (стани, дії, переходи, винагороди, дисконт).

Метрика Шарпа (Sharpe ratio) — відношення середньої дохідності понад безризикову ставку до її стандартного відхилення; нормалізована міра ефективності з урахуванням ризику.

Прослизання (slippage) — різниця між очікуваною ціною виконання угоди та фактичною ціною, що виникає через обмежену ліквідність ордербуку.

Просадка (drawdown) — поточне відхилення вартості портфеля від його історичного максимуму; ключова метрика ризику стратегії.

Reward shaping — техніка модифікації функції винагороди агента RL для прискорення навчання шляхом надання проміжних сигналів.

Спот-ринок (spot market) — сегмент ринку, на якому здійснюється купівля-продаж з негайною поставкою активу та оплатою; протилежність строковому ринку (ф'ючерси, опціони).

Стейблкоїн (stablecoin) — клас криптовалют, чия вартість прив'язана до зовнішнього активу (зазвичай долара США); приклади: USDT, USDC, DAI.

Тейкер-комісія (taker fee) — комісія, яку біржа стягує з учасника за виконання уже виставленого ордера (на відміну від мейкер-комісії за виставлення нового).

Look-ahead bias — методологічна помилка використання при формуванні торгового сигналу інформації, яка фактично не була доступна на момент прийняття рішення.

On-chain метрики (on-chain metrics) — характеристики активності блокчейн-мережі, доступні з публічних блокчейн-даних (кількість активних адрес, обсяг транзакцій, hashrate тощо).

Flash crash — раптове різке падіння ціни активу за дуже короткий проміжок часу (хвилини) з подальшим частковим або повним відновленням.

FOMO (Fear Of Missing Out) — психологічний феномен ірраціонального страху пропустити можливість, що часто призводить до купівлі активу на максимумах.

HODL — сленговий термін криптоспільноти (від hold), що означає стратегію довгострокового утримання активу незалежно від поточної ринкової динаміки.

Walk-forward валідація — методологія оцінки моделей часових рядів, у якій тренувальна, валідаційна та тестова вибірки строго слідують одна за одною у часі без перекриття; усуває look-ahead bias.

Stop-loss — заздалегідь встановлений рівень ціни, при досягненні якого позиція автоматично закривається з метою обмеження потенційного збитку.

Take-profit — заздалегідь встановлений рівень ціни, при досягненні якого позиція автоматично закривається з метою фіксації досягнутого прибутку.