

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ХЕРСОНСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ**

Кваліфікаційна наукова праця
на правах рукопису

САВЧЕНКО СЕРГІЙ ОЛЕКСАНДРОВИЧ

УДК 004.415:[005.942:330.332.1]

ДИСЕРТАЦІЯ

**РОЗРОБЛЕННЯ АВТОМАТИЗОВАНОЇ ІНФОРМАЦІЙНОЇ СИСТЕМИ
ФІНАНСОВОГО КОНСУЛЬТУВАННЯ ДЛЯ ГЕНЕРАЦІЇ
ПЕРСОНАЛІЗОВАНИХ ІНВЕСТИЦІЙНИХ ПОРТФЕЛІВ**

Спеціальність 121 Інженерія програмного забезпечення
12 Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії

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

 С. О. Савченко

Науковий керівник – Кобець Віталій Миколайович,
доктор економічних наук, професор кафедри комп'ютерних наук та
програмної інженерії Херсонського державного університету

Івано-Франківськ - Херсон – 2025

АНОТАЦІЯ

Савченко С. О. Розроблення автоматизованої інформаційної системи фінансового консультування для генерації персоналізованих інвестиційних портфелів. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 121 Інженерія програмного забезпечення. Херсонський державний університет МОН України; Херсон, 2025.

Дисертаційну роботу присвячено вирішенню актуальної науково-практичної задачі розроблення автоматизованої інформаційної системи фінансового консультування, призначеної для генерації персоналізованих інвестиційних портфелів. Актуальність обраної тематики пояснюється необхідністю забезпечення доступних та ефективних фінансових консультацій широкому колу користувачів, зокрема у контексті високої інфляції та обмеженої ефективності традиційних способів заощадження, таких як банківські депозити.

У вступі до роботи розкрито актуальність теми, визначено мету, завдання, об'єкт, предмет і методи дослідження. Зазначено, що сучасні системи автоматизованого фінансового консультування (Robo-Advisors) набувають популярності завдяки доступності, зручності використання, низькому порогу входу та можливості налаштування персоналізованих параметрів інвестиційних портфелів.

Перший розділ дисертації присвячено аналізу сучасних досліджень за темою дисертаційної роботи та існуючих підходів у сферах автоматизованих систем фінансового консультування та застосуванню засобів машинного навчання у фінансовій галузі. Доведено актуальність застосування методів і алгоритмів машинного навчання, зокрема нейронних мереж LSTM, для прогнозування ціни фінансових інструментів. Проаналізовано переваги

поєднання класичної теорії Марковіца з сучасними методами машинного навчання, що дозволяє значно підвищити ефективність інвестиційних рішень. Також у першому розділі висвітлюються проблеми, з якими можуть зіштовхнутися інвестори-початківці. Зазначено важливість психологічних аспектів і врахування індивідуальних особливостей інвесторів.

Другий розділ присвячено обґрунтуванню методологічних підходів до задач прогнозування цін на фінансові інструменти, побудови початкового інвестиційного портфелю та його подальшому ребалансуванні. Також в другому розділі представлено розроблену архітектуру системи фінансового консультування, яка передбачає використання мікросервісної архітектури. Описано модулі прогнозування цін фінансових інструментів, формування та ребалансування портфелів, а також можливості взаємодії з користувачами через месенджери. Детально обґрунтовано використання моделі Марковіца та моделей прогнозування на основі множинної лінійної регресії та нейронних мереж LSTM. Також описано модель забезпечення постійного рівня споживання за допомогою алгоритму, що дозволяє визначити оптимальний розподіл заощаджень для інвесторів.

Третій розділ присвячений експериментальному тестуванню запропонованих методів та алгоритмів. Проведені дослідження показали високу ефективність LSTM-мереж для прогнозування валютних пар з похибкою менше 0,5%. Алгоритм множинної лінійної регресії продемонстрував високу ефективність прогнозування ціни закриття для усіх типів активів, що розглядаються в дослідженні. Порівняльний аналіз різних методів формування інвестиційного портфелю показав перевагу використання прогнозних даних для зниження втрат інвестиційного портфеля у періоди ринкової нестабільності. Запропонований алгоритм ребалансування портфеля на основі фінансових індикаторів показав перевагу над традиційною стратегією «купи і тримай», забезпечуючи стабільність портфеля навіть у кризові періоди. У результаті дослідження створено практичне рішення у

вигляді чат-бота, що дозволяє автоматично надавати персоналізовані фінансові рекомендації широкому колу користувачів без спеціальних фінансових знань. Реалізована система забезпечує високу безпеку персональних даних, зручність використання та можливість подальшого масштабування.

Отримані теоретичні результати мають наукову новизну, яка полягає у поєднанні класичної портфельної теорії Марковіца з сучасними методами машинного навчання для підвищення якості інвестиційних портфелів. Також було експериментально доведено ефективність запропонованого автором алгоритму ребалансування інвестиційного портфелю, як під час економічного циклу зростання, так і в період глобальної рецесії. Практична значущість дослідження полягає у створенні окремих модулів автоматизованої системи фінансового консультування, які можуть бути впроваджені в повноцінний Robo-Advisor сервіс відповідно до розробленої архітектури.

Ключові слова: автоматизована інформаційна система, фінансове консультування, персоналізований інвестиційний портфель, Robo-Advisor, LSTM нейронні мережі, множинна лінійна регресія, портфельна теорія Марковіца, прогнозування цін, ребалансування інвестиційного портфелю, машинне навчання.

Список опублікованих праць за темою дисертації:

1. Savchenko S., Kobets V. Development of Robo-Advisor System for Personalized Investment and Insurance Portfolio Generation. CCIS Series volume of ICTERI 2021 Workshops Proceedings, Volume 1635, chapter 14. 2022. pp 213-228. https://doi.org/10.1007/978-3-031-14841-5_14 (Scopus);
2. Savchenko, S., Kobets, V. Development of Software Architecture and Machine Learning Modules of Robo-Advisor System for Personalized Investment Portfolio Generation. Communications in Computer and

- Information Science, Volume 1698. Springer, Cham. 2022. pp 153–179.
https://doi.org/10.1007/978-3-031-20834-8_8 (Scopus);
3. Kobets V., Savchenko S. Using Telegram Bots for Personalized Financial Advice for Staff of Manufacturing Engineering Enterprises. Advances in Design, Simulation and Manufacturing V - Proceedings of the 5th International Conference on Design, Simulation Manufacturing: The Innovation Exchange, DSMIE-2022. 2022. pp 561–571.
https://doi.org/10.1007/978-3-031-06025-0_55 (Scopus);
 4. Kobets V., Savchenko S. Building an Optimal Investment Portfolio with Python Machine Learning Tools. CEUR Workshop Proceedings, Volume 3347. 2022. pp. 307–315 (Scopus);
 5. Savchenko, S., Kobets, V. Increasing Investment Portfolio Profitability with Computer Analysis Trading Strategies. Communications in Computer and Information Science, 2023, 1980, pp. 252–264.
https://doi.org/10.1007/978-3-031-48325-7_19 (Scopus);
 6. Savchenko, S., Kobets, V. Allocation of Investment Portfolio Assets Classes Using Machine Learning. Information and Communication Technologies in Education, Research, and Industrial Applications. ICTERI 2024. Communications in Computer and Information Science. Volume 2359. 2025. pp. 285–296. https://doi.org/10.1007/978-3-031-81372-6_21.

ANNOTATION

Savchenko S. Development of an Automated Financial Advisory Information System for Generating Personalized Investment Portfolios. – Qualifying scientific work on manuscript rights.

Dissertation for obtaining the scientific degree a Doctor of Philosophy in the specialty 121 Software engineering. Kherson State University, MES of Ukraine; Kherson, 2025.

The dissertation is devoted to solving the relevant scientific and practical problem of developing an automated financial consulting information system to generate personalized investment portfolios. The relevance of the chosen topic is explained by the need to provide accessible and effective financial advice to a wide range of users, particularly in the context of high inflation and the limited effectiveness of traditional savings methods, such as bank deposits.

The introduction reveals the topic's relevance and defines the study's purpose, objectives, object, subject, and methods. It is noted that modern automated financial advisory systems (Robo-Advisors) are gaining popularity due to their accessibility, ease of use, low entry threshold, and the ability to customize personalized parameters of investment portfolios.

The first section of the dissertation is devoted to the analysis of current research on the topic of the study and existing approaches in the areas of automated financial advisory systems and the use of machine learning tools in the financial industry. The relevance of using machine learning methods, particularly LSTM neural networks, for forecasting the value of financial instruments is proved. The advantages of combining the classical Markowitz theory with modern machine learning methods are analyzed, which can significantly improve the efficiency of investment decisions. The first section also highlights the problems that novice

investors may face. The importance of psychological aspects and considering individual investor characteristics is highlighted.

The second section is devoted to substantiating methodological approaches to forecasting prices for financial instruments, building an initial investment portfolio, and its subsequent rebalancing. The second section also presents the developed architecture of the financial advisory system, which involves microservice architecture. The modules for forecasting the prices of financial instruments, forming and rebalancing portfolios, and the possibilities of interaction with users through messengers are described. The use of the Markowitz model and forecasting models based on multiple linear regression and LSTM neural networks is substantiated in detail. The study also describes a model for ensuring a constant level of consumption, which allows for determining the optimal distribution of savings for investors.

The third section is devoted to experimental testing of the proposed methods and algorithms. The studies have shown the high efficiency of LSTM networks for forecasting currency pairs with an error of less than 0.5%. The multiple linear regression algorithm has demonstrated high efficiency in predicting the closing price for all types of assets considered in the study. A comparative analysis of different methods of investment portfolio formation has shown the advantage of using forecast data to reduce investment portfolio losses in times of market instability. The proposed algorithm of portfolio rebalancing based on financial indicators has shown an advantage over the traditional 'buy and hold' strategy, ensuring portfolio stability even in times of crisis. The study resulted in a practical solution: a chatbot that automatically provides personalized financial advice to a wide range of users without special financial knowledge. The implemented system ensures high security of personal data, ease of use, and the possibility of further scaling.

The obtained theoretical results have a scientific novelty, combining the classical Markowitz portfolio theory with modern machine learning methods to improve the quality of investment portfolios. The algorithm's effectiveness for

rebalancing an investment portfolio proposed by the author has been experimentally proven during the economic growth cycle and the global recession. The study's practical significance lies in creating individual modules of an automated financial advisory system that can be implemented in a full-fledged Robo-Advisor service per the developed architecture.

Keywords: automated information system, financial consulting, personalised investment portfolio, Robo-Advisor, LSTM neural networks, multiple linear regression, Markowitz portfolio theory, price forecasting, investment portfolio rebalancing, machine learning.

List of published works on the topic of the dissertation:

1. Savchenko S., Kobets V. Development of Robo-Advisor System for Personalized Investment and Insurance Portfolio Generation. CCIS Series volume of ICTERI 2021 Workshops Proceedings, Volume 1635, chapter 14. 2022. pp 213-228. https://doi.org/10.1007/978-3-031-14841-5_14 (Scopus);
2. Savchenko, S., Kobets, V. Development of Software Architecture and Machine Learning Modules of Robo-Advisor System for Personalized Investment Portfolio Generation. Communications in Computer and Information Science, Volume 1698. Springer, Cham. 2022. pp 153–179. https://doi.org/10.1007/978-3-031-20834-8_8 (Scopus);
3. Kobets V., Savchenko S. Using Telegram Bots for Personalized Financial Advice for Staff of Manufacturing Engineering Enterprises. Advances in Design, Simulation and Manufacturing V - Proceedings of the 5th International Conference on Design, Simulation Manufacturing: The Innovation Exchange, DSMIE-2022. 2022. pp 561–571. https://doi.org/10.1007/978-3-031-06025-0_55 (Scopus);
4. Kobets V., Savchenko S. Building an Optimal Investment Portfolio with Python Machine Learning Tools. CEUR Workshop Proceedings, Volume 3347. 2022. pp. 307–315 (Scopus);

5. Savchenko, S., Kobets, V. Increasing Investment Portfolio Profitability with Computer Analysis Trading Strategies. Communications in Computer and Information Science, 2023, 1980, pp. 252–264. https://doi.org/10.1007/978-3-031-48325-7_19 (Scopus);
6. Savchenko, S., Kobets, V. Allocation of Investment Portfolio Assets Classes Using Machine Learning. Information and Communication Technologies in Education, Research, and Industrial Applications. ICTERI 2024. Communications in Computer and Information Science. Volume 2359. 2025. pp. 285–296. https://doi.org/10.1007/978-3-031-81372-6_21.

ЗМІСТ

АНОТАЦІЯ.....	2
ЗМІСТ	10
СПИСОК УМОВНИХ СКОРОЧЕНЬ	12
ВСТУП.....	13
РОЗДІЛ 1. СУЧАСНІ ДОСЛІДЖЕННЯ В ГАЛУЗІ РОЗРОБКИ АВТОМАТИЗОВАНИХ СИСТЕМ ФІНАНСОВОГО КОНСУЛЬТУВАННЯ	18
1.1 Завдання та основні функції систем автоматизованого фінансового консультавання.....	18
1.2 Сучасні підходи до формування інвестиційних портфелів	27
1.3 Використання методів машинного навчання для побудови та підвищення прибутковості інвестиційних портфелів	49
1.4 Прикладне застосування нейронних мереж глибокого навчання в системах персоналізованого фінансового консультавання	74
1.5 Роль алгоритмічних торгових стратегій та аналізу фінансових індикаторів в управлінні інвестиційним портфелем	94
Висновки до розділу 1	113
РОЗДІЛ 2. МЕТОДОЛОГІЯ РОЗРОБКИ АВТОМАТИЗОВАНОЇ ІНФОРМАЦІЙНОЇ СИСТЕМИ ПЕРСОНАЛІЗОВАНОГО ФІНАНСОВОГО КОНСУЛЬТУВАННЯ	116
2.1 Архітектура автоматизованої системи фінансового консультавання .	116
2.2 Моделі формування інвестиційних портфелів.....	120
2.3 Методи прогнозування цін на фінансові інструменти та формування початкового інвестиційного портфелю з використанням методів машинного навчання.....	125
2.4 Використання фінансових індикаторів та засобів алгоритмічної торгівлі для формування інвестиційної стратегії.....	132
2.5 Використання месенджерів як платформи для взаємодії з системою автоматизованого фінансового консультавання.....	137
Висновки до розділу 2	144

РОЗДІЛ 3. РОЗРОБКА ПРОГРАМНИХ МОДУЛІВ АВТОМАТИЗОВАНОГО ФІНАНСОВОГО КОНСУЛЬТАНТА ТА АНАЛІЗ ЕФЕКТИВНОСТІ ОБРАНИХ МЕТОДІВ МАШИННОГО НАВЧАННЯ	147
3.1 Розробка модулів прогнозування цін на фінансові інструменти та формування інвестиційного портфелю.....	147
3.2 Використання прогнозованих значень цін фінансових інструментів при побудові інвестиційного портфелю	154
3.3 Використання машинного навчання для передбачення часток активів різних типів у початковому інвестиційному портфелі	160
3.4 Алгоритм автоматичного ребалансування для підвищення прибутковості інвестиційного портфелю	168
3.5 Розробка чат-боту для надання персональних фінансових рекомендацій	179
Висновки до розділу 3	183
ЗАГАЛЬНІ ВИСНОВКИ.....	186
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	189
ДОДАТКИ.....	206
Додаток А.....	206
Додаток Б	213

СПИСОК УМОВНИХ СКОРОЧЕНЬ

AI – Artificial Intelligence (штучний інтелект)

Bi-LSTM – Bidirectional LSTM (двонаправлений LSTM)

CM – Confusion Matrix (матриця помилок)

DL – Deep Learning (глибоке навчання)

ETF – Exchange-Traded Fund (біржовий інвестиційний фонд)

FinTech – Financial Technology (фінансові технології)

LSTM – Long Short-Term Memory (довготривала короткочасна пам'ять)

MACD – Moving Average Convergence Divergence (збіжність та розбіжність ковзних середніх)

MDD – Maximum Drawdown (максимальна просадка)

ML – Machine Learning (машинне навчання)

MLR – Multiple Linear Regression (множинна лінійна регресія)

RA – Robo-Advisor (автоматизований фінансовий консультант)

RSI – Relative Strength Index (індекс відносної сили)

S&R – Support and Resistance (підтримка та опір)

АФК – Автоматизований фінансовий консультант

МН – Машинне навчання

ШІ – Штучний інтелект

ВСТУП

Актуальність теми. Автоматизовані фінансові консультанти (АФК) – це системи, що надають певні види фінансових порад у сфері інвестування або страхування, також відомі як Robo-Advisors (RA). RA сервіси відносяться до сегменту управління активами у галузі фінансових технологій (FinTech), що вивчає використання інформаційних технологій у таких сферах, як банківська справа, страхування та інвестиції. RA сервіс – це тип автоматизованої інформаційної системи, яка надає інвестиційні поради з урахуванням цілей клієнта та забезпечує онлайн доступ до інформаційної панелі управління інвестиціями.

Більшість RA систем призначені для особистого використання. Вони надають інтуїтивно зрозумілий користувацький інтерфейс для таких функцій, як вибір інвестиційних цілей, встановлення прийнятної рівня ризику, бюджету та бажаних інвестиційних активів. Результатом роботи RA системи є план інвестиційного портфеля, заснований на історичних даних про ціни відповідних фінансових інструментів та персональній інформації, що надається користувачем.

Схема роботи кінцевого користувача (інвестора) з RA системою складається з наступних етапів:

- Анкетування користувача. Визначення рівня його доходів, відношення до ризику, інвестиційних цілей і часових обмежень.
- Аналіз отриманих від користувача даних для подальшої побудови персоналізованого інвестиційного плану з урахуванням даних про динаміку цін на певні фінансові інструменти в минулому.
- Представлення сформованого плану (інвестиційного портфелю) в інтерфейсі системи з можливістю зміни певних параметрів (наприклад,

виключення користувачем певного виду активів) та оновлення інвестиційного плану.

- Доступ користувача до інформаційної панелі RA системи для відслідковування динаміки інвестиційного портфелю та надання можливості його періодичного ребалансування.

Переваги RA систем у порівнянні з традиційними фінансовими радниками (доступність, низький поріг входу для нових користувачів, можливість точного налаштування параметрів формування інвестиційного портфелю, можливість введення особистої накопичувальної системи пенсійного забезпечення) спричинили активне зростання зацікавленості потенційних інвесторів у подібних сервісах та появи багатьох fintech стартапів, що пропонують послуги фінансових робо-консультантів на ринках Північної Америки, Європи та Азії. Однак в Україні подібні системи в загальнодоступному виді досі не представлені.

Мета й завдання дослідження. Метою дослідження є розроблення автоматизованої інформаційної системи фінансового консультування для генерації інвестиційних планів інвесторам із різною схильністю до ризику з використанням методів машинного навчання та відкритих даних про курси фінансових інструментів. Для досягнення поставленої мети було сформовано наступні завдання дослідження:

- аналіз сучасних програмних продуктів у сфері автоматизованого фінансового консультування в контексті визначення їх переваг і недоліків з урахуванням світового досвіду в розробці фінансових інструментів;
- опис математичних моделей прийняття інвестиційних рішень та побудови інвестиційних портфелів за критерієм «доходність-ризик» для клієнтів із різною схильністю до ризику;
- аналіз алгоритмів машинного навчання, що можуть застосовуватись для вирішення задач прогнозування часових рядів (на прикладі цін на

фінансові інструменти) та формування інвестиційних портфелів; порівняння ефективності застосування різних алгоритмів машинного навчання для кожної із задач;

- проектування високорівневої архітектури системи автоматизованого фінансового консультанта для формування інвестиційних планів на основі відкритих даних про курси фінансових інструментів та інформації про клієнта;
- прикладна реалізація основних програмних модулів системи автоматизованого фінансового консультування з алгоритмами пошуку, обробки та аналізу даних щодо курсів фінансових інструментів задля автоматизованого створення та оновлення (ребалансування) інвестиційних планів клієнтів.

Об'єкт та предмет дослідження.

Об'єкт дослідження – автоматизований фінансовий консультант (Robo-Advisor).

Предмет дослідження – розробка модулів автоматизованої інформаційної системи фінансового консультування для генерації персоналізованих інвестиційних планів інвесторам із різною схильністю до ризику на основі відкритих даних про курси фінансових інструментів.

Методи дослідження. До методів дослідження, використаних у процесі роботи над дисертаційною роботою, входять:

- теоретичний аналіз математичних моделей, що використовуються для формування інвестиційних портфелів за критерієм «доходність-ризик»;
- практична реалізація обраних підходів до формування інвестиційних портфелів (що в загальному випадку є прикладами оптимізаційних задач) з використанням мікросервісної архітектури та порівняльний аналіз їх ефективності за показниками ризикованості та дохідності;

- реалізація та порівняльний аналіз ефективності застосування різних технік машинного навчання, зокрема, множинної лінійної регресії та використання LSTM нейронних мереж, для прогнозування курсу фінансових інструментів на основі часових рядів і для автоматизованого ребалансування інвестиційних портфелів.

Наукова новизна одержаних результатів.

Вперше описано та експериментально доведено ефективність методу формування персоналізованого інвестиційного портфелю, який поєднує класичну теорію портфельних інвестицій Марковіца з методами машинного навчання для прогнозування цін фінансових інструментів, що дозволяє підвищити точність прогнозування та ефективність інвестиційних рішень.

Вперше розроблено алгоритм автоматичного ребалансування інвестиційного портфелю, який базується на поєднанні аналізу сигналів фінансових індикаторів із використанням LSTM нейронних мереж, що дозволяє своєчасно реагувати на зміни на фінансовому ринку.

Набуло подальшого розвитку розроблення високорівневої архітектури системи автоматизованого фінансового консультування, що, на відміну від більшості існуючих методів, включає модулі прогнозування цін, формування та ребалансування портфелю в єдиному інтегрованому рішенні, що дозволяє підвищити ефективність управління інвестиціями.

Практичне значення одержаних результатів. Прикладним результатом проведеного дослідження є реалізація програмних модулів системи для генерації персоналізованих інвестиційних портфелів, яка може використовуватися клієнтами без спеціальних навичок у фінансовій галузі.

Апробація результатів дисертації. Основні положення, проміжні висновки та результати були представлені на міжнародних наукових конференціях, PhD симпозиумах та воркшопах впродовж 2021 – 2024 рр., а саме: воркшоп міжнародної конференції «Information and Communication

Technologies in Education, Research, and Industrial Applications», 28 вересня 2021 р., Херсон, Україна; міжнародна конференція «Design, Simulation, Manufacturing: The Innovation Exchange», 7-10 червня 2022 р., Познань, Польща; «IX International conference “Information Technology and Implementation”», 30 листопада – 2 грудня 2022 р., Київ, Україна; PhD симпозиум конференції «18th International Conference on ICT in Education, Research, and Industrial Applications», 18-22 вересня 2023 р., Івано-Франківськ, Україна; PhD симпозиум конференції «19th International Conference on ICT in Education, Research, and Industrial Applications», 23-27 вересня 2024 р., Львів, Україна.

Зв'язок роботи з науковими планами та темами. Дисертаційне дослідження виконувалося в рамках кафедральних науково-дослідних робіт: “Аналіз даних у цифровому автоматизованому і персоналізованому раднику для формування інвестиційних портфелів клієнтів” (державний реєстраційний номер: 0122 U 201061, термін виконання НДР: 2022-2027 рр.) та “Виконання завдань перспективного плану розвитку наукового напрямку «Технічні науки» в Херсонському державному університеті за період з 2021 по 2026 роки” (державний реєстраційний номер: 0122 U 000045, термін виконання НДР: 2021-2026 рр.).

Публікації. Основні результати дисертаційної роботи викладено в 6 наукових працях. Усі праці опубліковано у виданнях Springer та CEUR-WS, що індексуються в наукометричній базі Scopus. Опубліковані праці висвітлюють зміст дисертації.

Структура й обсяг дисертації. Дисертаційна робота складається зі вступу, основної частини, що містить три розділи, загальних висновків, списку використаних джерел, додатків. Повний обсяг дисертаційної роботи – 219 сторінок, із яких 171 сторінка – основний текст (таблиць – 24, рисунків – 31, лістингів – 10, формул – 16, додатків – 2).

РОЗДІЛ 1.

СУЧАСНІ ДОСЛІДЖЕННЯ В ГАЛУЗІ РОЗРОБКИ АВТОМАТИЗОВАНИХ СИСТЕМ ФІНАНСОВОГО КОНСУЛЬТУВАННЯ

1.1 Завдання та основні функції систем автоматизованого фінансового консультування

Індекс інфляції (або індекс споживчих цін) – це показник, який характеризує зміну загального рівня цін на товари та послуги, які населення купує для особистого споживання. В Україні індекс інфляції становив 5%, 10% і 26,6% у 2020, 2021 і 2022 роках відповідно. На кінець 2022 року рівень інфляції перевищив 20%, і український уряд заклав очікуваний індекс інфляції на рівні 28% при плануванні державного бюджету на 2023 рік [1]. Традиційні методи захисту заощаджень від інфляції, такі як банківські депозити та облігації, не здатні компенсувати знецінення грошових заощаджень населення за такого високого рівня зростання індексу споживчих цін.

Як результат, люди, які прагнуть принаймні зберегти свої заощадження, шукають альтернативні способи зробити це. Одним із таких рішень є інвестування в цінні папери, акції, ETF та інші фінансові інструменти. Однак, якщо людині бракує досвіду у фінансовій галузі, фінансової грамотності, існує високий ризик неправильного формування інвестиційного портфеля, наприклад, недотримання правил диверсифікації активів. Для допомоги у складанні інвестиційного плану особам, які не мають спеціалізованих навичок та компетентностей, були розроблені спеціальні програмні інструменти, які називаються Robo-Advisor, або автоматизовані системи фінансового консультування.

Наразі різноманітні цифрові фінансові інструменти знаходять своє застосування в багатьох сферах фінансової індустрії. Найпопулярнішими

випадками використання є кредитний скоринг, оцінка страхових ризиків, виявлення шахрайства, управління ризиками тощо. Ще одним популярним продуктом FinTech галузі за останнє десятиліття стали автоматизовані фінансові консультанти [2].

АФК системи є частиною сегменту управління активами в індустрії фінансових технологій (FinTech). FinTech означає використання інформаційних технологій у таких сферах, як банківська справа, страхування та інвестування [3]. RA сервіс дозволяють почати інвестувати навіть тим, хто не має великого стартового капіталу. Багато RA сервісів не мають обмеження на мінімальний розмір портфеля, що розширює їхню цільову аудиторію.

Ще однією перевагою використання RA систем є те, що, на відміну від класичних фінансових консалтингових компаній, які пропонують скласти індивідуальний інвестиційний портфель за досить високу ціну, послуги RA стягують відносно невелику комісію за транзакцію, а деякі з них мають лише фіксовану річну комісію. Це приваблює інвесторів-початківців і знижує поріг входу для потенційних клієнтів.

RA система – це тип фінансового радника, який надає інвестиційні консультації та забезпечує онлайн-доступ до інформаційної панелі управління інвестиціями. Він складається з інтерактивних та інтелектуальних компонентів допомоги користувачеві [4]. Більшість RA систем призначені для особистого використання. Вони надають інтуїтивно зрозумілий користувацький інтерфейс для таких функцій, як вибір інвестиційних цілей, визначення рівня допустимого ризику, бюджету та бажаних інвестиційних активів. Результатом роботи RA системи є інвестиційний портфель, що базується, окрім іншого, на вхідній інформації, наданій користувачем. Загальні характеристики RA систем включають наступне:

- Інвестиційні поради в онлайн режимі на основі відповідей користувача на спеціалізовану анкету [5];

- Повна відсутність або мінімум живого контакту між інвесторами та платформою;
- Можливість динамічно змінювати особисті налаштування (очікувану норму прибутку, ставлення до ризику, тощо) та ребалансувати інвестиційний портфель.

Основні переваги RA систем порівняно з традиційними фінансовими консультаційними установами (доступність, низький рівень початкового бюджету для нових клієнтів, можливість тонкого налаштування параметрів інвестиційного портфеля, можливість планування накопичувальної пенсійної системи) стимулюють активний інтерес потенційних інвесторів до таких послуг. Як наслідок, це призводить до появи багатьох фінтех-стартапів, що пропонують послуги фінансового консультування на ринках Північної Америки, Європи та Азії. Однак, такі системи ще не набули широкого розповсюдження у Східній Європі та, зокрема, в Україні.

Розробники RA повинні пам'ятати, що більшість людей не знайомі з професійними економічними термінами і правилами, і вони не можуть самостійно сформулювати свої особисті інвестиційні цілі, які зазвичай включають коротко-, середньо- і довгострокові фінансові цілі. Тому перше завдання автоматизованого фінансового консультанта – це зібрати якомога більше інформації про користувача. Інформація має включати вік, річний дохід, суму витрат, інвестиційну мету, період інвестування, прийнятний рівень ризику, бажані активи тощо. Вихідна інформація повинна містити детальний інвестиційний план із зазначенням частки кожного активу в портфелі, очікуваної норми прибутку та можливих щорічних просідань портфеля. Важливо також подавати інформацію чітко і зрозуміло, щоб підвищити рівень довіри користувачів.

Різноманітні законодавчі обмеження не дозволяли традиційним фінансовим установам реагувати на нові потреби споживачів, що призвело до появи так званих FinTech-компаній. Зміни в традиційній концепції

інвестування та страхування формують нову сферу на ринку фінансових послуг (FinTech-послуги). FinTech-послуги надаються технологічними компаніями за допомогою спеціального програмного забезпечення та орієнтовані на фінансові потреби клієнтів [6]. Аналіз фінтех-послуг представлено в табл. 1.1.

Таблиця 1.1

Аналіз фінтех-послуг

Потенційні переваги фінтех-послуг	Ризики фінтех-послуг
<i>Децентралізація та диверсифікація</i> фінансових послуг призвела до посилення конкуренції між традиційними та RA-радниками, підвищення якості послуг, зменшення впливу на ринок окремих фінансових компаній, легкого доступу та низької мінімальної суми інвестицій для інвесторів з низьким бюджетом.	<i>Кібер-ризики</i> (більш широке використання технологій та цифрових рішень розширює діапазон і кількість точок входу, які можуть бути атаковані хакерами).
<i>Ефективність</i> - завдяки сучасним технологічним підходам (використання методів машинного навчання та штучного інтелекту для покращення процесів прийняття рішень та оптимізації) – нижчі витрати. RA системи не приймають рішень на основі емоцій.	<i>Правові / регуляторні ризики</i> (у деяких країнах існують різні правові невизначеності, наприклад щодо смарт-контрактів та автоматизованих систем, що надають інвестиційні поради).
<i>Стабільність</i> фінтех-послуг завдяки зменшенню інформаційної асиметрії між надавачами фінансових послуг та клієнтами, використанню смарт-контрактів для зниження ризиків, краудфандингу для фінтех-стартапів.	<i>Системний ризик</i> (складна алгоритмічна торгівля викликає нові шоки на фінансових ринках). Невизначений результат роботи алгоритму RA через екстремальні падіння ринку та/або екстремальні ринкові зрушення.

Джерело: розроблено автором на основі [7].

Перші RA системи в сучасному вигляді веб-сервісів були створені наприкінці 2000-х років під час фінансової кризи 2007-2008 років [2, 8]. На

сьогодні існує понад 100 Robo-Advisor систем [8], які мають широкий спектр функцій. Деякі з них орієнтовані на інвесторів-початківців і мають невеликий мінімальний розмір рахунку, в той час як інші орієнтовані на більш досвідчених інвесторів і мають обмеження на мінімальний розмір інвестицій.

Базельський комітет з банківського нагляду (BCBS) зазначає, що фінтех-послуги з управління активами (RA-сервіси) мають наступні ключові особливості [9]:

- сервіси працюють тільки у вигляді веб-додатків або програмних додатків для смартфонів чи комп'ютерів;
- всі послуги надаються без участі традиційних фінансових посередників;
- сервіси використовують автоматизований механізм, заснований на математичних алгоритмах;
- сервіси забезпечують високу швидкість операцій.

Отже, Robo-Advisor – це сервіс онлайн-управління портфелем, що надає автоматизовані, засновані на певних алгоритмах, консультаційні поради. Протягом наступних кількох років можна очікувати, що платформи RA-консультантів стануть засобом доступу до ще більшого переліку послуг, а новим клієнтам буде запропоновано страхування життя та пов'язані з ним продукти [10]. Технологічні інновації та конкуренція у фінансовій галузі змушують ринок надавати повністю автоматизовані інвестиційні рішення, що залежать від індивідуальних параметрів кожного з інвесторів, які мають різні рівні доходів та уподобання до ризиків.

Наразі платформи автоматизованого фінансового консультування не пропонують рішень для більш складних фінансових потреб, таких як страхування або пенсійне забезпечення, які складають всі інші аспекти особистого фінансового планування, що вирішуються фінансовими консультантами-людьми. Ретельно проаналізувавши сучасні дослідження [11, 12], можна зробити висновок, що деякі з найпопулярніших RA-платформ (Betterment, FutureAdvisor, Motif Investing, Schwab Intelligent та Wealthfront)

мають в більшості однакові ключові функції, включаючи інвестиційні поради, автоматизоване інвестування, пенсійне планування та обслуговування клієнтів. Однак є деякі унікальні функції, які представлені лише в деяких з них:

- Пайові інвестиційні фонди (доступні лише в Betterment, FutureAdvisor та Wealthfront);
- Ребалансування портфеля недоступне в Motif Investing;
- Двофакторна автентифікація доступна тільки в Betterment.

Порівняння ключових відмінностей між автоматизованими та традиційними фінансовими консультантами наведено в табл. 1.2.

Таблиця 1.2

Порівняння характеристик автоматизованих та традиційних фінансових консультантів

Характеристики консультанта	Автоматизований Robo-Advisor	Традиційне консультування
Обслуговування клієнтів	Інвестор дистанційно взаємодіє з онлайн-сервісом і надає всю інформацію через веб-інтерфейс або мобільний додаток.	Особисте спілкування з фінансовим консультантом, заповнення анкети інвестором особисто з фінансовим консультантом.
Цілі інвестування	Автоматизована оцінка типових коротко- і середньострокових цілей інвестора.	Індивідуальна оцінка для визначення довго- і короткострокових цілей інвестора.
Послуги консультації	Відсутність "живого" радника, онлайн-сервіс пропонує автоматизовані рекомендації щодо формування інвестиційного портфеля.	Фінансові експерти особисто залучені до процесу управління активами клієнта та формування його інвестиційного портфеля.
Комісії	0,25%-0,50% на рік. Низький (нульовий) поріг входу та низька комісія (створює можливості для	1%-2% на рік. Високий поріг входу та вища комісія (доступ для

	інвесторів з невеликими капіталами).	інвесторів з переважно високими доходами).
Методи формування інвестиційного портфеля	Алгоритмічні методи на основі сучасної портфельної теорії, моделі Марковіца-Тобіна, моделі Блека-Літтермана для оптимізації прибутковості та ризику (середньо-варіаційна оптимізація).	Аналітичні методи, що базуються на досвіді фінансових консультантів, статистичних показниках прибутковості та ризику фінансових інструментів.
Фінансові інструменти	Біржові інвестиційні фонди (ETF), криптовалюти, акції, облігації.	Депозити, акції, облігації, пайові інвестиційні фонди.
Стратегії	Пасивні індексні стратегії (RA слідує за індексом ETF, включаючи його прогноз) з меншою кількістю транзакцій на рік.	Стратегії активного управління активами з більшою кількістю транзакцій на рік.
Ребалансування портфеля	Автоматичне ребалансування в певних межах відхилення. Можливість налаштування умов ребалансування «на ходу».	Визначається компанією з управління активами з урахуванням вимог інвестора.
Робочий час	24/7	Визначений графік робочих годин.

Джерело: розроблено автором на основі [11, 12].

RA-сервіси повинні діяти відповідно до фінансового законодавства тих ринків, на яких вони доступні. Це стосується і страхування рахунків. Роборадники, які, наприклад, працюють на ринку США, не застраховані Федеральною корпорацією страхування депозитів (FDIC), оскільки вони оперують не банківськими депозитами, а цінними паперами, що утримуються з метою інвестування. Натомість вони, як і звичайні фінансові консультанти,

страхують свої рахунки через Корпорацію захисту інвесторів у цінні папери (SIPC) [13].

Дослідження, що охопило 219 систем, які можна вважати RA-сервісами [3], показує, що більшість із них використовують сучасну теорію портфеля Гаррі Марковіца як основу для побудови персоналізованих інвестиційних портфелів.

В сучасних RA системах широко використовуються технології машинного навчання для прогнозування часових рядів. Порівняння найбільш популярних алгоритмів прогнозування часових рядів з використанням машинного навчання представлено в табл. 1.3. Інструменти, що використовують засоби штучного інтелекту, застосовуються для рекомендацій щодо складу інвестиційного портфелю, ребалансування портфелю та моніторингу доходів і витрат [14].

Таблиця 1.3

**Порівняння деяких алгоритмів машинного навчання
для прогнозування часових рядів**

Алгоритм	Переваги	Недоліки
Лінійна регресія	Можливість обробляти різні компоненти та предиктори часового ряду; Висока інтерпретованість.	Чутливість до викидів; Сильні припущення.
Random Forest (випадковий ліс)	Інтуїтивно зрозумілі правила прийняття рішень; Враховує взаємодію між предикторами; Може працювати з нелінійними предикторами.	На виході немає рейтингу; Високе зміщення в бік навчальної вибірки.
K-Nearest Neighbors (K найближчих сусідів)	Можливість обробляти рівні зі змінними, трендами та сезонними компонентами; Автоматизована оптимізація.	Чутливість до викидів; Вузькі довірчі інтервали.

Support vector machine (метод опорних векторів)	Висока інтерпретованість; Реалістичні довірчі інтервали; Реалістичні прогнози.	Потрібно багато даних; Суворі обмеження та припущення; Складність автоматизації.
Нейронна мережа з довготривалою короткочасною пам'яттю (LSTM)	Невелика кількість обмежень і припущень; Можливість обробляти складні нелінійні шаблони; Здатність запам'ятовувати довгострокові предиктори та висока якість прогнозу; Легко автоматизується.	Низька інтерпретованість; Важко визначити довірчі інтервали для прогнозу; Потрібно багато даних і часу на навчання.

Базуючись на результатах, викладених у дослідженні [3], клієнти RA-сервісів вказують на наступні недоліки:

- не відповідають особистим потребам;
- відсутність контакту з людиною-консультантом;
- низька довіра клієнтів;
- низька прозорість;
- обмежена пропозиція.

Вказані недоліки повинні бути враховані при розробці архітектури та користувацького інтерфейсу RA системи. Основним недоліком традиційного інвестиційного консультування є обмежена доступність через необхідний обсяг активів і високі витрати на управління. Для вирішення цих недоліків розробляються автоматизовані сервіси, які використовують штучний інтелект та алгоритми без участі фізичного радника, тим самим зменшуючи або скасовуючи мінімальні вимоги щодо початкового капіталу та знижуючи витрати [10]. Деякі дослідники [10] припускають, що RA сервіси є не загрозою для традиційних фінансових консультантів, а їхнім доповненням, що робить гібридну модель, яка поєднує фізичного консультанта з технологічними рішеннями, найбільш оптимальною.

Підсумовуючи завдання й особливості сучасних сервісів персоналізованого фінансового консультування, було складено блок-схему з описом загального робочого процесу RA системи (рис. 1.1), що включає блоки введення інформації від користувача, збір та обробку ринкових даних, аналітичний модуль, а також модулі формування, оптимізації та ребалансування інвестиційного портфелю.

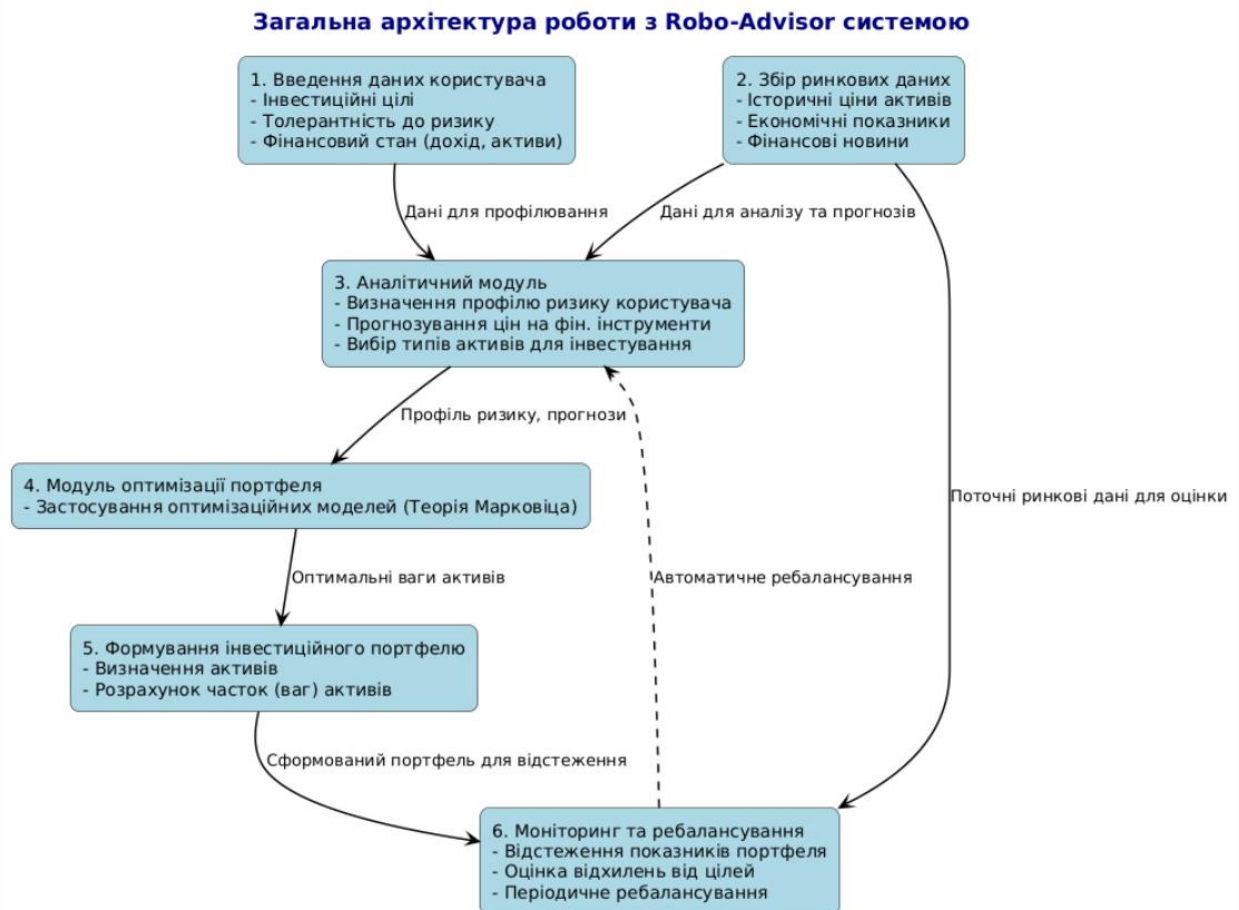


Рисунок 1.1. Загальна архітектура роботи з Robo-Advisor системою.

1.2 Сучасні підходи до формування інвестиційних портфелів

Автоматизовані системи фінансового консультування мають розроблятися з урахуванням персональних особливостей інвесторів-початківців, які не мають вузькопрофільних знань у фінансовій галузі та попереднього досвіду інвестування. Однією з небезпек для інвесторів-новачків є схильність до так званої стадної поведінки – явища, при якому люди

свідомо чи несвідомо наслідують дії більшості, не проводячи власного аналізу та не зважаючи на індивідуальні інвестиційні цілі. В одному з досліджень [15] було проаналізовано явище стадної поведінки серед індивідуальних інвесторів на фондовому ринку Швеції. Автор досліджує чинники стадної поведінки на рівні окремих акцій та індивідуальних інвесторів, а також порівнює ефективність портфелів інвесторів, що демонструють стадну поведінку, з ринком загалом та з портфелями інвесторів, яким не притаманна стадна поведінка. В дослідженні застосовуються алгоритми машинного навчання, зокрема Random Forest, для визначення найважливіших предикторів стадної поведінки. Для інтерпретації результатів Random Forest використовуються значення SHAP (SHapley Additive exPlanations), а для відбору найважливіших предикторів застосовується рекурсивне виключення ознак (RFE). Результати дослідження показують, що на рівні акцій стадна поведінка пояснюється ефектом диспозиції (передчасний продаж активів, які зросли в ціні, або ж занадто довге утримання активів, які знизились в ціні) та ефектом уваги (тенденція інвесторів фокусуватися на акціях або активах, які привертають їхню увагу, незалежно від їхніх фундаментальних показників). Явище стадної поведінки більш виражене для акцій великих компаній та компаній із низьким співвідношенням балансової до ринкової вартості. На рівні індивідуальних інвесторів високі значення кумулятивної кількості покупок і вартості портфеля зменшують імовірність стадної поведінки, тоді як високі значення дохідності портфеля незначно її збільшують. Висока ліквідність і співвідношення ринкової до балансової вартості акцій у портфелі також зменшують ймовірність прояву стадної поведінки. Дослідження демонструє, що показники портфелів інвесторів, які демонструють стадну поведінку, не перевершують ані ринок, ані портфелі інвесторів без стадної поведінки, що вказує на те, що стадна поведінка є поведінковим упередженням. Також було показано, що ефекти стадної поведінки можуть призводити до короткострокового неправильного утворення цін на фінансові інструменти. Спираючись на результати даного дослідження, можна зробити висновок, що

недосвідчені інвестори більш схильні до імпульсивних та необґрунтованих дій при самотійному формуванні та ребалансуванні інвестиційних портфелів. Таких небажаних ефектів можна уникнути шляхом використання автоматизованих систем фінансового консультування, які позбавлені впливу ефектів диспозиції, уваги та інших, пов'язаних з психологією інвестора.

Окремо варто виділити новітні підходи до формування інвестиційних портфелів, які поєднують традиційні методи та використання методів машинного навчання. У дослідженні [16] представлено підхід до формування інвестиційного портфеля, що базується на концепції колективного інтелекту та методах глибокого навчання. Дослідники розробили механізм, який аналізує дописи інвесторів на соціальній фінансовій платформі StockTwits та використовує історичні дані про ціни акцій для створення оптимальних за критерієм «ризик-дохідність» інвестиційних портфелів. Ключовою особливістю запропонованого підходу є використання колективного інтелекту інвесторів – концепції, яка передбачає, що об'єднані знання та судження великої групи інвесторів можуть призвести до кращих інвестиційних рішень, ніж рішення окремих експертів. Для аналізу колективного інтелекту автори застосували ряд методів, включаючи аналіз настроїв (sentiment analysis) постів інвесторів, оцінку впливовості авторів, та використання методу TF-IDF для виявлення ключових слів. Для прогнозування цін на фінансові інструменти було застосовано LSTM нейронну мережу, що дозволило врахувати не лише думки інвесторів, а й прогнозовані значення цін, які отримуються з урахуванням динаміки зміни цін у минулому. Алгоритм, запропонований в дослідженні, включає кілька ключових етапів: збір і попередня обробка даних, аналіз думок інвесторів та їх впливу, прогнозування трендів акцій, визначення уподобань і схильності до ризику інвестора або групи інвесторів, формування оптимального інвестиційного портфеля. Особливу увагу приділено оцінці ризику за допомогою бета-коефіцієнта (показник ризику для портфеля цінних паперів) та формуванню портфелів з урахуванням індивідуальної схильності

до ризику. Результати дослідження показали, що запропонований підхід перевершив ринкові індекси (DJIA та S&P 500) та інші еталонні методи за різними фінансовими показниками, включаючи середню доходність за період утримання та коефіцієнти Шарпа, Дженсена і Трейнора. Це демонструє ефективність поєднання колективного інтелекту та методів машинного навчання для формування інвестиційних портфелів. Одним із можливих перспективних напрямків покращення підходу формування інвестиційних портфелів, запропонованого авторами, є аналіз настроїв інвесторів за допомогою великих мовних моделей (large language models) замість традиційних методів обробки природньої мови (natural language processing), таких як підрахунок заздалегідь визначених ключових слів.

Побудова початкового інвестиційного портфеля є головним завданням для будь-яких фінансових систем, пов'язаних із інвестиціями. Класичний підхід, запропонований Гаррі Марковіцем у 1952 році, базується на оптимізації співвідношення ризику та прибутковості, та використовує лише дані про прибутковість обраних активів у минулому. Однак, зростаюча складність фінансових ринків і доступність більшої кількості даних призвели до розробки більш складних методів формування портфелів. Одним із таких підходів є застосування багатокритеріальних методів прийняття рішень (MCDM) для вибору інвестиційного портфеля. В дослідженні [17] представлено комбіновану модель CRITIC-GRA, що поєднує методи Criteria Importance Through Intercriteria Correlation (CRITIC) та Grey Relational Analysis (GRA) для ранжування інвестиційних альтернатив. Ця модель враховує широкий спектр фінансових показників, включаючи дивідендну прибутковість, рентабельність інвестованого капіталу, рентабельність власного капіталу, чисту маржу, показники ліквідності, волатильність, ринкову вартість, тощо. Такий підхід дозволяє провести більш комплексний аналіз фінансових інструментів порівняно з класичною моделлю Марковіца. Основною відмінністю запропонованого методу від класичного підходу

Марковіца є багатоетапність процесу формування портфеля. Спочатку проводиться багатокритеріальний аналіз для відбору найбільш перспективних активів, а потім застосовується оптимізація Марковіца для визначення оптимальних ваг цих активів у портфелі. Це дозволяє врахувати не лише статистичні характеристики прибутковості, але й фундаментальні показники компаній. Крім того, застосування п'яти нормалізацій у методі CRITIC-GRA підвищує надійність процесу прийняття рішень і зменшує суб'єктивність інвестора при виборі активів. Результати дослідження показали, що портфель, сформований за допомогою запропонованої моделі, перевершив ринковий індекс IBOV за показниками прибутковості, ризику та коефіцієнту Шарпа (Sharpe Ratio - міра безризикова доходність/ризик, що враховує загальну волатильність). Це свідчить про потенційну ефективність застосування багатокритеріальних методів у формуванні інвестиційних портфелів та відкриває перспективи для подальших досліджень у цьому напрямку, зокрема, щодо застосування інших MCDM методів та розширення набору критеріїв для оцінки фінансових інструментів.

У іншому дослідженні, також присвяченому проблемі оптимізації інвестиційного портфеля, проведено дослідження, спрямоване на вдосконалення процесу оптимізації інвестиційного портфеля за допомогою поєднання методу опорних векторів (SVM) та портфельної теорії Марковіца [18]. Основною метою дослідження було використання моделі SVM для попереднього відбору активів на основі фундаментальних показників на бразильському фондовому ринку та подальша оптимізація відбору шляхом максимізації коефіцієнта Шарпа. Дослідження охопило 89 компаній, що входили до індексу IBOVESPA, протягом 10-річного періоду (2013–2023 рр.). Основні атрибути для SVM включали такі показники, як рентабельність власного капіталу (ROE), рентабельність активів (ROA), дивідендний дохід тощо. Результати цього дослідження показали, що модель SVM продемонструвала точність класифікації на рівні 61%, що свідчить про

здатність алгоритму ефективно відбирати активи на основі фундаментальних індикаторів. Після відбору активів було проведено оптимізацію портфеля за допомогою моделі Марковіца з метою максимізації коефіцієнта Шарпа. Отриманий портфель продемонстрував значно вищу ефективність порівняно з ринковим еталоном (індекс IBOVESPA) та наївною стратегією SVM-1/n за такими показниками, як коефіцієнт Шарпа, Трейнора, Сортіно та сукупний середньорічний темп зростання (Compound Annual Growth Rate, CAGR). Зокрема, портфель, оптимізований за допомогою SVM, показав значно швидше відновлення після періодів просідання, що підкреслює його здатність до адаптації в умовах ринкової волатильності. Таким чином, це дослідження робить важливий внесок у сучасну теорію портфельного інвестування, підтверджуючи ефективність застосування моделі SVM для попереднього відбору активів у поєднанні з оптимізаційною моделлю Марковіца. Результати дослідження свідчать про доцільність використання таких комбінованих підходів для підвищення ефективності інвестиційних стратегій в автоматизованих системах фінансового консультування.

Інше дослідження [19] пропонує новий підхід до прогнозування трендів на фондовому ринку та формування оптимального інвестиційного портфеля. Основною інновацією цієї роботи є застосування перетворення Гільберта-Хуанга (ННТ) для виділення більш інформативних ознак із часових рядів цін акцій. Автори припустили, що ці ознаки можуть покращити точність прогнозування напрямку зміни ціни закриття акцій, що, в свою чергу, дозволить формувати більш ефективні інвестиційні портфелі. Методологія дослідження базувалася на комбінації кількох сучасних технік аналізу даних та оптимізації. Зокрема, автори використали алгоритм машинного навчання XGBoost (Extreme Gradient Boosting) для класифікації трендів цін акцій. Для формування оптимального інвестиційного портфеля було застосовано класичну модель середнього-дисперсії Марковіца, оптимізовану за допомогою методу послідовного квадратичного програмування (SLSQP). Додатково було

проведено симуляцію методом Монте-Карло для дослідження характеристик випадкових портфелів. Результати дослідження продемонстрували значну перевагу запропонованого підходу ННТ-XGB (комбінація ННТ і XGBoost) порівняно з традиційними методами. Точність класифікації напрямку зміни ціни для ННТ-XGB склала 81%, що на 30% перевищує результати стандартного XGBoost. Стратегія торгівлі, базована на прогнозах ННТ-XGB, показала вищу прибутковість і менші ризики порівняно з іншими розглянутими стратегіями. Зокрема, середньорічне значення коефіцієнта Шарпа для ННТ-XGB склало 4,52, що свідчить про високу ефективність запропонованого підходу. Дане дослідження робить вагомий внесок у розвиток методів прогнозування фінансових ринків та оптимізації інвестиційних портфелів. Застосування перетворення Гільберта-Хуанга для аналізу фінансових часових рядів відкриває нові можливості для покращення точності прогнозів та, як наслідок, підвищення ефективності інвестиційних стратегій. Отримані результати можуть бути корисними як для подальших академічних досліджень, так і для практичного застосування у сфері алгоритмічної торгівлі, що може бути одним із сервісів Robo-Advisor системи.

Задля розуміння принципів формування збалансованого та добре диверсифікованого портфелю важливо звернути увагу на сучасні роботи щодо вивчення взаємозв'язків між різними класами активів. Наприклад, одне з нещодавніх досліджень [20] фокусується на аналізі зв'язків між акціями та токенами, пов'язаними зі штучним інтелектом. Це дослідження охоплює період з травня 2019 року по січень 2023 року, включаючи такі події, як пандемія COVID-19 та російське вторгнення в Україну, що також дозволяє оцінити вплив глобальних кризових явищ на взаємозв'язки між різними фінансовими інструментами. Методологічною основою даного дослідження є підхід квантильної зв'язності. Цей метод дозволяє аналізувати взаємозв'язки між активами на різних рівнях розподілу доходності, що є суттєвим удосконаленням порівняно з традиційними методами, які зазвичай

фокусуються лише на середніх значеннях. Квантильна зв'язність враховує можливі нелінійні та асиметричні ефекти, які можуть виникати при різних ринкових умовах. Автори застосовують цей підхід до набору з п'яти акцій компаній, пов'язаних з ІІІ (включаючи такі гіганти як Microsoft, Alphabet, Amazon), та п'яти токенів ІІІ, що дозволяє провести комплексний аналіз взаємодії між традиційними та новими фінансовими інструментами. Результати дослідження мають вагомий результат для теорії та практики фінансового менеджменту. Зокрема, вони виявили, що токени, пов'язані з ІІІ, демонструють нижчий ступінь перетікання доходності від інших активів, що робить їх потенційно ефективними інструментами для диверсифікації портфеля. Важливим спостереженням є те, що рівень зв'язності між активами суттєво вищий на екстремальних кінцях розподілу доходності, ніж на медіані. Це вказує на посилення взаємозв'язків між активами в періоди значних ринкових коливань, що особливо важливо враховувати при управлінні ризиками. Динамічний аналіз, проведений авторами, показує, що зв'язність між активами змінюється з часом, з помітним посиленням під час ключових глобальних подій. Ці результати підкреслюють важливість врахування макроекономічного контексту при аналізі фінансових ринків та управлінні інвестиційними портфелями.

У сучасній фінансовій науковій літературі зокрема вивчається вплив психологічних факторів на поведінку інвесторів та їх ефективність на фондовому ринку. Одне з таких досліджень [21] фокусується на аналізі взаємозв'язку між особистісними характеристиками інвесторів та їх торговими результатами. Автори використовують модель "великої п'ятірки" особистості (екстраверсія, доброзичливість, сумлінність, невротизм, відкритість досвіду) як основу для оцінки особистісних рис інвесторів. Крім того, дослідження враховує вплив соціальних та етичних цінностей, таких як справедливість, ввічливість, сміливість і відповідальність, а також демографічних факторів на торгові показники. Методологія дослідження включає експериментальний

підхід, де 146 студентів брали участь у двомісячному симульованому торговому конкурсі на віртуальній фондовій біржі. Дані про особистісні характеристики учасників були зібрані за допомогою опитувань. Для аналізу отриманих даних автори використовували комбінацію статистичних методів, включаючи логістичну регресію, лінійну регресію та тобіт-регресію. Додатково було застосовано методи машинного навчання, зокрема алгоритм кластеризації K-means, для групування інвесторів за їхніми характеристиками. Результати дослідження мають важливе значення для розробки та вдосконалення систем автоматизованого фінансового консультування (Robo-Advisor). Виявлені закономірності, зокрема те, що інвестори з вищим рівнем відкритості до нового досвіду та невротизму демонструють кращі результати порівняно з ринковим бенчмарком, можуть бути використані для налаштування параметрів інвестиційних рекомендацій. При розробці Robo-Advisor систем доцільно включити модуль оцінки особистісного профілю користувача, який враховуватиме не лише традиційні параметри толерантності до ризику, але й характеристики "великої п'ятірки" особистості. Виявлений позитивний вплив соціальних рис, таких як справедливість і ввічливість, на ефективність торгівлі може бути використаний для розробки більш персоналізованих інвестиційних стратегій. Важливим аспектом є врахування рівня самооцінки інвестора, оскільки дослідження показало, що надмірна самовпевненість може призводити до гірших результатів. Застосування методів машинного навчання в дослідженні демонструє потенціал використання технологій машинного навчання для кластеризації інвесторів та адаптації інвестиційних рекомендацій відповідно до їх профілю. Такий підхід дозволить створювати більш ефективні та персоналізовані Robo-Advisor системи, які враховуватимуть не лише фінансові показники, але й психологічні характеристики інвесторів.

В роботі “Optimal stock allocation for an automated portfolio recommender system in the perspective of maximum fund utilization” [22] автори

зосереджуються на розробці автоматизованої системи рекомендацій портфелів для непрофесійних інвесторів з метою максимального використання інвестиційного капіталу. Проблема вибору оптимальної комбінації акцій у портфелі ускладнюється динамічністю ринкових коливань і поведінковими факторами, що впливають на інвесторів. Для вирішення цих завдань у роботі було використано дані про закриття цін та об'єми торгів для 297 акцій, представлених на Національній фондовій біржі Індії за 2021–2022 фінансовий рік. Кластеризація акцій за допомогою алгоритму K-means дозволила визначити групи несхожих акцій на основі додаткових параметрів, таких як бета-фактор та пропорційний об'єм торгів. Такий підхід покращив процес диверсифікації портфелів, що є ключовим для зниження ризиків. Подальший аналіз базувався на застосуванні портфельної теорії Марковіца (MPT), що дозволило збалансувати очікуваний дохід і ризик для кожного портфеля. Для оптимізації розподілу активів було використано два підходи: алгоритм жадібної оптимізації та задачу цілочисельного програмування. Порівняння цих методів показало, що алгоритм жадібної оптимізації забезпечує краще використання інвестиційного капіталу, що робить його ефективнішим у випадках, коли необхідно максимізувати фондовий дохід. Крім того, результати дослідження підтверджують перевагу моделі MPT над моделлю ієрархічної паритетності ризиків (HRP), навіть в умовах ринкової кризи. Показники портфелів, згенерованих на основі MPT, продемонстрували вищу дохідність за збереження прийнятного рівня ризику, що підтверджується значеннями коефіцієнта Шарпа. Загалом, дослідження робить вагомий внесок у розвиток автоматизованих систем рекомендацій портфелів для непрофесійних інвесторів, особливо у контексті використання портфельної теорії Марковіца для оптимізації інвестиційних рішень. Окрім цього, робота акцентує увагу на значущості застосування кластеризації та методу жадібної оптимізації для підбору диверсифікованих портфелів, що знижують ризики без суттєвого зменшення прибутковості.

Один із методів побудови добре диверсифікованого інвестиційного портфеля на основі прогнозування доходності акцій з використанням методів машинного навчання представлено у дослідженні [23]. Автори застосували п'ять методів машинного навчання для прогнозування доходності акцій: Random Forest (RF), Support Vector Regression (SVR), Long Short-Term Memory (LSTM), Extreme Learning Machine (ELM) та Back Propagation Neural Network (BPNN). Для вимірювання рівня диверсифікації використовувався коефіцієнт кореляції Пірсона, а для визначення ваг активів у портфелі - модифікована модель середньої дисперсії (MMV). Запропонований метод складається з двох етапів. На першому етапі відбувається відбір акцій з високим прогнозованим доходом та низькою кореляцією між собою. Другий етап передбачає оптимальний розподіл коштів між відібраними акціями з використанням MMV моделі та методу Монте-Карло для генерації можливих ваг. Оптимальний портфель обирається на основі найвищого коефіцієнта Шарпа. Результати дослідження показали, що модель Random Forest продемонструвала найкращі результати прогнозування доходності акцій порівняно з іншими методами. Автори визначили оптимальний поріг диверсифікації 0,6, який забезпечує баланс між максимізацією доходності та мінімізацією ризиків. Запропонована модель RF+MMV (Random Forest + модифікована модель середньої дисперсії) перевершила інші моделі та ринковий індекс за показниками доходності та співвідношенням ризик/доходність. Важливо відзначити, що портфелі, побудовані на основі запропонованого методу, показали кращі результати навіть із урахуванням транзакційних витрат. Модель RF+MMV продемонструвала найвищу кумулятивну доходність за досліджуваний період 2014-2020 рр. Отже, дослідження пропонує ефективний інструмент для створення прибуткових і диверсифікованих інвестиційних портфелів, який поєднує переваги використання машинного навчання для прогнозування доходності акцій з класичними методами оптимізації портфеля.

Під час формування інвестиційного портфелю важливо враховувати загальні середньо- та довгострокові тенденції, пов'язані з розвитком інформаційних технологій, адже наразі вони тісно пов'язані з багатьма іншими сферами, такими як медицина, сільське господарство, логістика, тощо. Спостерігається зростання ролі технологічних активів та екологічно чистих інвестицій, що зумовлює необхідність дослідження їх взаємозв'язків з традиційними ринками. Автори одного з досліджень на дану тему [24] провели комплексний аналіз взаємозв'язків між технологічними активами (фінтех, криптовалюта, штучний інтелект) та традиційними фінансовими ринками й екологічно чистими активами. Результати дослідження виявили сильну асиметрію причинно-наслідкових зв'язків між технологічними та іншими активами. Зокрема, було встановлено, що фінтех, криптовалютні активи та фінансові активи, пов'язані зі штучним інтелектом, мають високу прогностичну інформаційну ефективність щодо основних ринків за нормальних умов, але ця здатність знижується за екстремальних ринкових ситуацій. Важливим результатом стало виявлення ефективних інструментів хеджування: індекси S&P Treasury Bond та S&P Green Bond показали високу ефективність у хеджуванні фінтех-акцій. Для акцій, пов'язаних зі штучним інтелектом, найкращим довгостроковим інструментом хеджування виявився індекс S&P Global Clean Energy. Ці результати мають важливе практичне значення для управління інвестиційними портфелями та оцінки ризиків на сучасних фінансових ринках, де технологічні інновації та екологічні фактори відіграють все більшу роль.

У статті "Portfolios with return and volatility prediction for the energy stock market" [25] досліджується ефективність використання прогнозування доходності та волатильності для складання інвестиційних портфелів на енергетичному ринку. Автори застосували алгоритм XgBoost, який є вдосконаленим методом градієнтного бустінгу на основі дерев рішень, для прогнозування майбутньої доходності та волатильності компонентів індексу

CSI Energy. Дослідження показало, що поєднання цих прогнозів з існуючими портфельними моделями дозволяє підвищити ефективність портфелів, а саме збільшити доходність і знизити ризики. Для оцінки результатів були використані шість класичних портфельних моделей: MV (Mean-Variance), MSV (Mean Semi-Variance), Omega, CVaR (Conditional Value at Risk), MAD (Mean Absolute Deviation) та MSAD (Mean Semi-Absolute Deviation). Автори модернізували ці моделі шляхом інтеграції прогнозованих значень доходності та волатильності. Наприклад, модель MV була доповнена прогнозами для оптимізації портфеля на основі майбутньої середньої доходності та ризику, а модель CVaR включила прогнозовані втрати в екстремальних випадках. Найкращі результати виявила модель CVaR з прогнозованими вагами (CVaR-F-PW), яка продемонструвала найбільшу загальну доходність і низький рівень ризику з оптимальним рівнем довіри в 90%. Це свідчить про те, що поєднання прогнозованої доходності та волатильності може суттєво підвищити ефективність управління енергетичними портфелями, зокрема з точки зору максимізації доходу та мінімізації ризиків. Окрім цього, автори запропонували підхід до використання ваг на основі прогнозів (Prediction-Based Weights). Такий підхід дозволяє динамічно змінювати ваги різних активів у портфелі залежно від прогнозованих показників, що, як було доведено, покращує ефективність інвестиційної стратегії. Використання Xgboost для прогнозування доходності та волатильності продемонструвало значно кращі результати, порівняно з використанням історичних даних, особливо в умовах мінливого ринку. Загалом, результати цього дослідження вказують на те, що впровадження методів машинного навчання у процес формування інвестиційних портфелів може стати ключовим фактором у підвищенні ефективності інвестицій в енергетичному секторі.

У контексті сучасних досліджень з оптимізації інвестиційних портфелів варто відзначити ще одну роботу, яка пропонує новітній підхід до вибору оптимального портфеля акцій. Дане дослідження [26] спрямоване на розробку

комплексної моделі, що інтегрує методи нечіткої логіки, аналітичної ієрархії та багатокритеріального прийняття рішень для вирішення задачі формування інвестиційного портфеля в умовах невизначеності фінансових ринків. Запропонована модель поєднує рандомізований зважений нечіткий метод аналітичної ієрархії (Randomized Weighted Fuzzy AHP) з методом TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution), використовуючи модифіковану нормалізацію для нечіткого АНР. Ключовою особливістю підходу є застосування нечіткої логіки для обробки невизначеності фінансових даних та експертних оцінок. Модель також включає аналіз чутливості для оцінки стабільності сформованого портфеля для різних ринкових сценаріях. При роботі з нечіткими даними використовуються лінгвістичні змінні та трикутні нечіткі числа (TFN), а для дефазифікації – центроїдний метод. Результати дослідження демонструють ефективність запропонованого підходу у формуванні інвестиційних портфелів із кращим співвідношенням ризику і прибутковості порівняно з традиційними методами. Модель дозволяє враховувати множинні фактори, такі як рентабельність активів (ROA), рентабельність власного капіталу (ROE), рентабельність задіяного капіталу (ROCE), коефіцієнт співвідношення позикових і власних коштів (DER), прибуток на акцію (EPS) та коефіцієнт ціна/балансова вартість (PBV). Це забезпечує більш комплексний підхід до оцінки потенційних інвестицій та формування надійних і адаптивних портфелів в умовах мінливості фінансових ринків. Таким чином, дане дослідження пропонує інструментарій для оптимізації інвестиційних рішень з урахуванням множинних критеріїв і ринкової невизначеності.

У іншому дослідженні [27] автори розглядають вплив геополітичних ризиків на волатильність фондового ринку США та можливості її прогнозування за допомогою методів машинного навчання. Автори аналізують вплив різних категорій геополітичних ризиків на волатильність індексу S&P 500 та оцінюють ефективність різноманітних методів машинного

навчання для прогнозування цієї волатильності. Дослідники застосовують широкий спектр методів машинного навчання, включаючи LASSO, Elastic Net, згорткові нейронні мережі (CNN), байєсівську регресію, метод опорних векторів для регресії (SVR) та випадковий ліс (Random Forest). Крім того, вони використовують методи комбінування прогнозів, такі як середнє значення, медіана, метод дисконтування середньоквадратичної помилки прогнозу (DMSPE) тощо. Результати дослідження показують, що серед геополітичних факторів найбільший вплив на волатильність S&P 500 мають військові нарощування, ескалація війни та терористичні акти. Методи машинного навчання демонструють кращу прогностичну здатність порівняно з базовою авторегресійною моделлю, причому найкращі результати серед індивідуальних методів показують SVR (support vector regression) та байєсівська регресія. Методи комбінування прогнозів також демонструють високу ефективність. Економічний аналіз, проведений авторами, свідчить про те, що використання прогнозів волатильності на основі методів машинного навчання дозволяє інвесторам досягти значних економічних вигод при оптимізації портфеля. Дослідження також підтверджує існування "головоломки комбінування прогнозів", показуючи, що простіші методи комбінування часто дають кращі результати, ніж складніші.

Дослідження прихованих ринкових взаємозв'язків, таких як зв'язки між валютними курсами та фондовими індексами, має важливе значення для розробки ефективних Robo-Advisor систем, оскільки розуміння цих взаємозалежностей дозволяє створювати більш точні алгоритми автоматизованого управління інвестиційними портфелями. Автори статті "Mining the co-movement between foreign exchange rates and category stock indexes in the Taiwan financial capital market" [28] зосередилися на вивченні взаємозв'язків між курсами іноземних валют та галузевими індексами акцій на фінансовому ринку Тайваню. Автори застосували методи інтелектуального аналізу даних, зокрема алгоритм Apriori для пошуку асоціативних правил,

використовуючи програмне забезпечення SPSS Clementine. Дослідження охопило 13 курсів валют відносно тайванського долара та 30 галузевих індексів акцій. Результати дослідження виявили значущі кореляції між певними валютами та галужевими індексами. Зокрема, було встановлено негативну кореляцію між японською єною та акціями текстильної, будівельної та паперової галузей, а також між гонконгським долларом та акціями машинобудівної та електронної галузей. Крім того, автори виявили прямі кореляції між валютами певних географічних регіонів, наприклад, між євро та швейцарським франком. На основі отриманих результатів, було запропоновано кілька інвестиційних портфелів для валют та акцій. Ці портфелі враховують виявлені взаємозв'язки та можуть бути адаптовані до різних ринкових умов. Автори також відзначають важливість врахування макроекономічних факторів при аналізі фінансових ринків. Ці рекомендації мають враховуватись під час розробки та вдосконаленні автоматизованих систем управління інвестиціями.

У статті “Optimizing investment portfolios with a sequential ensemble of decision tree-based models and the FBI algorithm for efficient financial analysis” представлено послідовний ансамблевий підхід до оптимізації інвестиційного портфеля [29]. Основною метою дослідження було створення ефективної стратегії вибору акцій шляхом інтеграції методів машинного навчання та метаевристичних алгоритмів, заснованих на фундаментальному фінансовому аналізі. Автори використовували веб-сканер для збору щоденних цін закриття акцій, щомісячних доходів і фінансових звітів компаній, які представлені на Тайванській фондовій біржі (TWSE) за період з 2013 до 2021 року. У статті застосовано три моделі машинного навчання на основі дерев рішень, а саме Random Forest (RF), eXtreme Gradient Boosting (XGBoost) та Light Gradient Boosting Machine (LightGBM), для виявлення ключових фінансових індикаторів, які значною мірою впливають на доходи компаній. Важливим компонентом дослідження стало застосування нового метаевристичного

алгоритму Forensic-Based Investigation (FBI), розробленого для оптимізації умов вибору акцій на основі фінансових показників. Для побудови інвестиційного портфеля застосовувалися три різні стратегії розподілу ваг: рівномірний розподіл (Equal-Weighting, EW), метод середньої дисперсії (Mean-Variance, MV) та ієрархічний розподіл ризику (Hierarchical Risk Parity, HRP). Результати дослідження продемонстрували, що запропонована стратегія інвестування, оптимізована за допомогою методів машинного навчання та алгоритму FBI, забезпечила значне перевищення прибутковості порівняно з традиційними підходами, підтверджуючи переваги інтеграції машинного навчання та метаевристичних алгоритмів для інвестиційного управління. Дослідження пропонує практичний інструмент для інвестиційних радників, який базується на інтеграції фінансового аналізу з інноваційними моделями машинного навчання та алгоритмами оптимізації і дозволяє ефективно визначати та оцінювати потенційно прибуткові акції на основі об'єктивних фінансових показників.

У дослідженні “Stock investment strategy combining earnings power index and machine learning” запропоновано підхід до середньострокового інвестування, що поєднує фундаментальний аналіз фінансової звітності з методами машинного навчання [30]. Автори зосередилися на використанні індексу потужності прибутку (EPI) як ключового інструменту для прогнозування майбутньої доходності акцій. Цей підхід відрізняється від традиційних методів тим, що дозволяє ефективно обробляти складні взаємозв'язки між фінансовими показниками та доходністю акцій. Методологія дослідження включає застосування десяти різних алгоритмів машинного навчання, серед яких були як класичні методи (наприклад, логістична регресія та метод опорних векторів), так і сучасні підходи, такі як нейронні мережі різних архітектур. Особливу увагу автори приділили ансамблевим методам, зокрема Random Forest, Gradient Boosting, XGBoost та LightGBM. Для оцінки ефективності моделей використовувалася бінарна

класифікація зростання/падіння доходності акцій, а також формування інвестиційних портфелів на основі отриманих прогнозів. Результати дослідження продемонстрували високу ефективність запропонованого підходу. Зокрема, більшість сформованих портфелів, що базувалися на EPI-факторах, показали позитивну доходність незалежно від обраного часового періоду. Найкращі результати були отримані при використанні нейронних мереж із двома шарами та сигмоїдною функцією активації для періодів інвестування 3 і 6 місяців. Важливим висновком стало те, що стратегії, засновані на 9 EPI-факторах, перевершили підходи, що використовували 6 або 15 змінних. Це підкреслює важливість ретельного відбору релевантних фінансових показників для прогнозування. Результати дослідження підтверджують потенціал інтеграції методів машинного навчання з традиційним фундаментальним аналізом для покращення інвестиційних стратегій.

У дослідженні [31] представлено новий підхід до оптимізації інвестиційного портфеля. Авторами було розроблено алгоритм під назвою PMP-WOA (Periodic Multi-Population Whale Optimization Approach), який базується на Whale Optimization Algorithm (WOA), вперше представленому в 2016 році [32]. WOA – це метаевристичний алгоритм оптимізації класу методів ройового інтелекту, що є ефективним у різноманітних задачах оптимізації. PMP-WOA розширює можливості стандартного WOA шляхом періодичного застосування кількох підпопуляцій для покращення пошуку рішень і впровадженню механізму обміну інформацією між підпопуляціями для підвищення точності. Важливим аспектом PMP-WOA є застосування навчання з підкріпленням, зокрема автоматів навчання, для адаптивного контролю параметрів алгоритму. Дослідження демонструє, що PMP-WOA перевершує інші сучасні алгоритми оптимізації за кількома ключовими показниками. Зокрема, алгоритм показав меншу відстань до реального фронту Парето, більшу кількість недомінованих рішень, краще розповсюдження рішень і

швидшу збіжність. Важливо відзначити, що PMP-WOA продемонстрував стабільну ефективність при різних розмірах портфеля та кількості доступних акцій. Алгоритм здатний створювати портфелі з оптимальним балансом між дохідністю, ризиком та ліквідністю, що є ключовими факторами в управлінні інвестиціями. Таким чином, дане дослідження пропонує новий інструмент для вирішення оптимізаційних задач при формування інвестиційних портфелів. PMP-WOA поєднує переваги класичного алгоритму WOA з новими механізмами, що дозволяє досягти вищої продуктивності в контексті оптимізації інвестиційного портфеля.

У статті "Portfolio constructions in cryptocurrency market: A CVaR-based deep reinforcement learning approach" було досліджено проблему оптимізації портфелів на криптовалютному ринку, що відзначається значним "хвостовим ризиком" (tail risk), характерним для цього сегмента фінансового ринку [33]. Автори запропонували застосування Conditional Value at Risk (CVaR) у поєднанні з технологіями глибокого навчання з підкріпленням (Deep Reinforcement Learning, DRL) для побудови ефективного портфеля криптовалют. Застосований метод глибокого навчання з підкріпленням був реалізований за допомогою алгоритму Proximal Policy Optimization (PPO), який є однією з найефективніших технік у даній сфері. Цей підхід дозволив моделі навчатися оптимальній стратегії управління портфелем у середовищі, яке моделюється як марковський процес прийняття рішень (MDP), без використання попередніх припущень щодо розподілу ризиків і прибутків. Результати дослідження виявили, що модель, заснована на CVaR, демонструє значно кращі показники ефективності у порівнянні з традиційною середньо-дисперсійною моделлю (mean-variance model). Оптимізація портфелів за допомогою CVaR привела до значного підвищення ефективної межі портфелів, що свідчить про покращення співвідношення ризику та дохідності. Зокрема, підхід на основі CVaR дозволив отримати портфелі з вищим середнім доходом при одночасному зниженні стандартного відхилення, що вказує на

менший рівень ризику порівняно з традиційними методами. Ці результати було підтверджено під час проведення тестування поза вибіркою (out-of-sample testing) з використанням історичних даних за період з січня 2019 до серпня 2021 року, де портфелі, побудовані за допомогою підходу CVaR, виявилися більш прибутковими та менш ризикованими. Практичні висновки дослідження підкреслюють переваги використання підходу на основі CVaR для інвесторів на криптовалютному ринку, оскільки ця методика дозволяє більш ефективно управляти "хвостовими ризиками" та забезпечувати захист від нестабільності, пов'язаної з зовнішніми ринковими шоками, такими як пандемія COVID-19 чи геополітичні конфлікти. Дослідження підкреслює, що застосування алгоритмів глибокого навчання з підкріпленням у поєднанні з показником CVaR є перспективним напрямком для побудови ефективних і збалансованих портфелів у контексті криптовалютного ринку.

Авторами ще одного дослідження, присвяченого задачі формування оптимального інвестиційного портфелю [34], розглядається підхід, який поєднує методи машинного навчання для прогнозування дохідності акцій з класичною моделлю оптимізації портфеля на основі середнього значення під ризиком (Mean-Value-at-Risk, MVaR). Автори провели порівняльний аналіз ефективності шести методів машинного навчання: Random Forest (RF), AdaBoost, XGBoost, Support Vector Regression (SVR), k-Nearest Neighbors (KNN) та Artificial Neural Network (ANN) для прогнозування дохідності акцій. Дослідження базувалося на щомісячних історичних даних 50 випадково обраних акцій з фондових бірж Індії, Японії та Китаю. Результати дослідження показали, що алгоритм AdaBoost продемонстрував найкращі показники прогнозування дохідності акцій серед усіх досліджених методів за критеріями MAE, MSE та RMSE. Цей факт підкреслює ефективність ансамблевих методів, зокрема бустингу, у вирішенні складних задач прогнозування на фінансових ринках. Подальший аналіз виявив, що інтеграція прогнозів AdaBoost з моделлю оптимізації MVaR (названа авторами Ada+MVaR) перевершила інші

комбінації методів у мінімізації Value-at-Risk (VaR) портфеля та максимізації кумулятивної дохідності. Важливо відзначити, що запропонований підхід продемонстрував стабільну ефективність на даних різних фондових ринків, що свідчить про його потенційну універсальність та адаптивність до різних ринкових умов. Це дослідження робить значний внесок у розвиток методів кількісного інвестування, демонструючи, як інтеграція передових методів машинного навчання з класичними моделями оптимізації портфеля може суттєво покращити ефективність інвестиційних стратегій.

Для підвищення ефективності традиційних методів оптимізації інвестиційного портфеля, низка досліджень пропонує інтеграцію методів машинного навчання, зокрема для попереднього відбору активів або для прогнозування їхніх характеристик. Такий підхід дозволяє врахувати складніші залежності та потенційно покращити співвідношення ризику та дохідності кінцевого портфеля. У табл. 1.4 представлено порівняльний аналіз ключових аспектів таких гібридних підходів, узагальнюючи методологію та результати розглянутих раніше досліджень [18, 23, 34].

Таблиця 1.4

**Порівняння підходів до оптимізації інвестиційного портфеля
з використанням ML**

Задача / Проблема	Методологія рішення	Ключові результати	Релевантність для RA систем
Вдосконалення оптимізації портфеля [18]	Застосування SVM для попереднього відбору активів (на основі фундаментальних показників) в поєднанні з портфелем Марковіца.	Модель показала значно вищу ефективність порівняно з еталоном та наївною стратегією, швидше відновлення після просідань.	Використання ML технік для попереднього відбору активів може суттєво покращити результати традиційних методів оптимізації портфелю.

Побудова диверсифікованого портфеля на основі прогнозу [23]	Прогнозування доходності (RF, SVR, LSTM, ELM, BPNN), Модифікована модель середньої дисперсії (MMV), Поріг кореляції Пірсона (0,6).	Random Forest показав найкращі результати прогнозування. Модель RF+MMV перевершила інші моделі та ринковий індекс.	Поєднання машинного навчання для прогнозування та моделей оптимізації дозволяє створювати краще диверсифіковані портфелі.
Підвищення ефективності інвестиційних стратегій [34].	Прогнозування доходності (AdaBoost та інші ML методи) + Оптимізація портфеля MVaR (Mean-Value-at-Risk).	Інтеграція прогнозів AdaBoost з моделлю MVaR (Ada+MVaR) перевершила інші комбінації, стабільна ефективність на різних ринках.	Інтеграція ансамблевих ML методів з моделями оптимізації, що враховують ризик, може суттєво покращити інвестиційні стратегії.

У дослідженні Капарріні та ін. [35] розглядається застосування методів машинного навчання для відбору акцій з індексу S&P 500 з метою перевищення доходності базового індексу. Автори зосередилися на трьох алгоритмах: дерево рішень, випадковий ліс та XGBoost. Ці методи були обрані завдяки їх здатності забезпечувати інтерпретованість результатів через аналіз важливості ознак, що є критичним для розуміння динаміки ринкових факторів. Методологія дослідження включає використання генетичних алгоритмів для оптимізації гіперпараметрів моделей та застосування крос-валідації з часовим розбиттям для мінімізації ризику перенавчання. Бектестинг проводився на історичних даних з 3 січня 2005 по 30 вересня 2019 року. Результати показали, що всі три стратегії перевершили індекс S&P 500 за доходністю, при цьому XGBoost продемонстрував найкращі показники з річною доходністю 11,26%

порівняно з 6,18% для індексу. Авторами також було проведено аналіз зміни важливості різних факторів для прогнозування доходності акцій з часом. Автори виявили значні зміни у важливості факторів в період 2009-2013 років, що може бути пов'язано з наслідками фінансової кризи 2008-2009 років. Це підкреслює здатність алгоритмів машинного навчання адаптуватися до змінних ринкових умов, що є критичним для довгострокового успіху інвестиційних стратегій. Варто зазначити, що дослідження має певні обмеження, зокрема, відсутність врахування транзакційних витрат, які можуть суттєво вплинути на реальну доходність стратегій. Крім того, фокус виключно на акціях індексу S&P 500 може обмежувати можливості диверсифікації портфеля. Незважаючи на це, результати дослідження демонструють потенціал використання методів машинного навчання для управління інвестиційними портфелями та підкреслюють важливість регулярного ребалансування та адаптації до змінних ринкових умов.

1.3 Використання методів машинного навчання для побудови та підвищення прибутковості інвестиційних портфелів

Автори дослідження, присвяченого вивченню ролі штучного інтелекту та машинного навчання у підвищенні конкурентоспроможності фінансових установ [36], застосовують якісний підхід до дослідження, аналізуючи вторинні дані з різноманітних джерел. Результати дослідження демонструють, що ШІ та МН суттєво трансформують фінансовий сектор, впливаючи на ключові аспекти галузі, такі як оцінка ризиків, виявлення шахрайства, надання консультаційних послуг, управління фінансами та трейдинг. Дослідники виявили, що застосування МН у фінансовій сфері має різний ступінь впливу залежно від конкретного напрямку. Зокрема, найбільший вплив спостерігається у сферах аналізу документів (90%), виявлення шахрайства (92%) та управління інвестиційними портфелями (86%). Ці дані свідчать про високий потенціал використання МН у системах Robo-Advisor, особливо в

модулях, пов'язаних із аналізом ризиків, управлінням портфелем та забезпеченням безпеки транзакцій. Автори також підкреслюють значення ШІ та МН у підвищенні ефективності та продуктивності фінансових послуг через автоматизацію процесів. Автори зазначають, що впровадження роботизованої автоматизації процесів (RPA) сприяє зниженню операційних витрат та оптимізації розподілу людських ресурсів. Це спостереження має важливе значення для розробки систем Robo-Advisor, оскільки вказує на потенціал для створення більш ефективних та економічно вигідних рішень у сфері автоматизованого управління інвестиціями. Особливу увагу в дослідженні приділено використанню МН в алгоритмічній торгівлі та управлінні портфелем. Автори підкреслюють, що алгоритми МН здатні адаптуватися до змін ринку в режимі реального часу, що є критичною конкурентною перевагою для фінансових установ. На відміну від людей, системи на основі МН приймають інвестиційні рішення без впливу емоційних факторів, що підвищує об'єктивність та ефективність управління активами. Крім того, дослідження показує, що МН успішно застосовується для створення персоналізованих інвестиційних рекомендацій, аналізуючи поведінку користувачів і ринкові тенденції для формування оптимальних інвестиційних стратегій.

У контексті інтенсивного розвитку технологій штучного інтелекту та машинного навчання, їх практична імплементація у фінансовому секторі набуває все більшого значення. Автори дослідження [37] здійснили комплексний бібліометричний аналіз наукових робіт щодо застосування штучного інтелекту та машинного навчання у сфері банківських послуг, фінансів та страхування. Дослідники застосували протокол PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses - протокол, призначений для покращення якості систематичних оглядів та мета-аналізів у наукових дослідженнях) для систематичного відбору та аналізу 1045 наукових публікацій з бази даних Scopus, використовуючи методи N-gram аналізу та

аналізу співвідношень для ідентифікації ключових тематичних напрямків та їх взаємозв'язків. Результати дослідження виявили 9 основних тематичних кластерів, що охоплюють широкий спектр застосувань ШІ та МН у фінансовій галузі. Серед них: трансформація банківського сектору під впливом фінтех-інновацій, роль ШІ та МН у підвищенні якості банківських послуг, застосування методів машинного навчання для оцінки ризиків та прогнозування, використання великих даних та ШІ для оптимізації фінансових продуктів, а також застосування ШІ в актуарних розрахунках та протидії фінансовим злочинам. Автори зафіксували експоненціальне зростання кількості публікацій протягом останнього десятиліття, що свідчить про зростаючий науковий і практичний інтерес до даної галузі. Суттєвим внеском цього дослідження є визначення ключових напрямків для подальших наукових пошуків. Зокрема, автори акцентують увагу на необхідності подальшого вивчення питань управління та регулювання фінтех-інновацій, підвищення фінансової та цифрової грамотності в контексті нових технологій, розробки методологій оцінки ризиків у цифрових фінансових послугах, а також дослідження етичних аспектів застосування ШІ у фінансовій сфері. Автори наголошують на важливості міждисциплінарного підходу та інтенсифікації співпраці між академічним і промисловим секторами для ефективного розвитку та імплементації ШІ та МН у фінансовій галузі.

В іншому систематичному огляді літератури [38] проаналізовано застосування методів машинного навчання у фінансовій сфері. Дослідники розглянули 126 статей із 44 журналів, опублікованих з 2015 року, що охоплюють шість ключових фінансових областей: прогнозування фондового ринку, управління портфелем, криптовалюти, валютний ринок (форекс), прогнозування фінансових криз та прогнозування банкрутства і неплатоспроможності. Для проведення систематичного огляду була використана методологія PRISMA, що забезпечило структурований та всебічний підхід до аналізу літератури. Автори детально розглянули

застосування різноманітних алгоритмів машинного навчання, включаючи класичні методи (k-NN, байєсівські класифікатори, дерева рішень, Random Forest, SVM), методи глибокого навчання (ANN, CNN, RNN, LSTM), навчання з підкріпленням та гібридні й ансамблеві моделі. Особлива увага була приділена аналізу характеристик даних і ознак, що використовуються для навчання моделей, оцінці підходів до валідації та аналізу метрик ефективності. Крім того, було проведено бібліометричний аналіз для розуміння поточного стану досліджень у цій галузі. Результати дослідження виявили зростаючу тенденцію застосування методів машинного навчання у фінансовій сфері, особливо для прогнозування фондового ринку та криптовалют. Методи глибокого навчання, зокрема LSTM, продемонстрували найкращі результати для прогнозування часових рядів фінансових даних. SVM виявився найбільш популярним методом для прогнозування банкрутства та неплатоспроможності. Автори також відзначили, що гібридні та ансамблеві моделі часто перевершують окремі моделі за точністю прогнозів. Важливим висновком стало те, що включення текстових даних, таких як новини та дані з соціальних медіа, значно покращує точність фінансових прогнозів. Географічний аналіз показав, що Китай, Індія та США є лідерами за кількістю публікацій у цій галузі. З технічної точки зору, Python виявився найпопулярнішою мовою програмування для розробки моделей машинного навчання у фінансах. Загалом, це дослідження демонструє широке застосування та ефективність методів машинного навчання у різних фінансових додатках, вказуючи на перспективні напрямки для подальших досліджень у цій галузі.

Інша група дослідників [39] також провела комплексний бібліометричний огляд літератури щодо застосування технологій штучного інтелекту та машинного навчання у сфері фінансів. Автори проаналізували 348 статей, опублікованих у 2011-2021 роках у провідних фінансових журналах, індексованих у базі даних Scopus. Для аналізу були використані методи

бібліометрії, аналізу цитувань, мережевого та контент-аналізу, а також спеціалізоване програмне забезпечення, таке як RStudio, VOSviewer та Excel. Результати дослідження виявили зростаючий тренд публікацій з 2015 року, що свідчить про підвищення інтересу до застосування ІІ та МН у фінансовій сфері. Автори визначили основні напрямки застосування цих технологій, серед яких прогнозування банкрутства, прогнозування цін на акції, управління портфелем, прогнозування цін на нафту, протидія відмиванню грошей, поведінкові фінанси, аналіз великих даних і блокчейн. Варто відзначити, що США, Китай і Велика Британія були визначені як країни з найбільшим внеском у дослідження в цій галузі. Було виділено шість основних напрямків досліджень: прогнозування банкрутства та оцінка кредитного ризику; прогнозування цін акцій, управління портфелем, волатильність і ліквідність; прогнозування цін на нафту, золото та сільськогосподарську продукцію; протидія відмиванню грошей, виявлення шахрайства та управління ризиками; поведінкові фінанси та аналіз великих даних. Огляд показав, що методи сучасних ІІ та МН, такі як нейронні мережі, методи опорних векторів, дерева рішень широко застосовуються у різних сферах фінансів і демонструють високу ефективність порівняно з традиційними економетричними методами. Дане дослідження також підкреслює зростаючу важливість міждисциплінарного підходу, що поєднує фінансову експертизу з глибоким розумінням технологій ІІ та МН.

У рамках ще одного систематичного огляду літератури [40] було досліджено застосування методів штучного інтелекту у сфері фінансової торгівлі. Дослідники здійснили ґрунтовний аналіз різноманітних аспектів, включаючи типи фінансових ринків та активів, методи аналізу торгівлі, конкретні техніки ІІ та метрики оцінки ефективності моделей. Дослідження охоплювало різноманітні технології: від традиційного машинного навчання до передових методів глибокого навчання та навчання з підкріпленням. Результати огляду виявили кілька ключових тенденцій у застосуванні ІІ для

фінансової торгівлі. Зокрема, було ідентифіковано 8 типів фінансових ринків, що досліджуються, причому фондовий ринок виявився найпопулярнішим об'єктом дослідження. Цікаво, що технічний аналіз використовується частіше, ніж фундаментальний, що може вказувати на перевагу кількісних методів у сучасних дослідженнях. Щодо конкретних методів ШІ, дослідження показало, що глибоке навчання (30% статей), навчання з підкріпленням (29%) та глибоке навчання з підкріпленням (29%) є найпопулярнішими підходами. Загалом було виявлено 40 різних технік ШІ, які часто використовуються у гібридних моделях. Це підкреслює різноманітність і складність методів, що застосовуються у сучасних дослідженнях фінансової торгівлі. Важливо відзначити, що дослідники використовують різні метрики для оцінки ефективності своїх моделей, включаючи RMSE, точність, повноту та F-міру для оцінки прогнозів, а також фінансові показники, такі як коефіцієнт Шарпа, норма прибутку та максимальна просадка для оцінки інвестиційної ефективності. Автори також відзначили, що лише 16% досліджених рішень повністю автоматизують торговий процес, що свідчить про потенціал подальшого розвитку в цьому напрямку.

Інше дослідження [41] представляє огляд тенденції застосування технологій штучного інтелекту та машинного навчання у фінансовій сфері за ширший часовий період. В ньому було проведено бібліометричний аналіз 283 статей, опублікованих у провідних міжнародних журналах з 1986 по квітень 2021 року. Автори застосували комплексний підхід, використовуючи методи аналізу цитування, бібліографічного сполучення, аналізу спільного вживання та аналізу збігів для виявлення ключових тем, тенденцій і взаємозв'язків у дослідженнях ШІ та МН у фінансах. Результати дослідження виявили 9 основних кластерів за аналізом цитування та 8 кластерів за бібліографічним сполученням, які можна об'єднати у три ключові групи: 1) побудова портфеля, оцінка активів та поведінка інвесторів; 2) фінансове шахрайство і фінансові труднощі; 3) аналіз настроїв, прогнозування і планування. Це свідчить про

широкий спектр застосування ШІ та МН у фінансових дослідженнях, від традиційних задач управління портфелем до новітніх напрямків аналізу настроїв ринку. Аналіз часових тенденцій показав еволюцію досліджень від розрізнених тем до початку 2009 року до фокусування на ціноутворенні та оцінці в період 2009-2015 років, і подальшого зміщення акценту на аналіз тексту, настроїв і великих даних у фінтех-сфері в 2015-2021 роках. Це відображає загальну тенденцію до цифровізації фінансової галузі та зростаючу роль аналізу даних у прийнятті фінансових рішень. Дослідження також виявило, що найбільш часто використовуваними методами ШІ та МН у фінансових дослідженнях є машинне навчання з учителем, обробка природної мови та застосування штучних нейронних мереж. Це підкреслює важливість розвитку компетентностей у цих областях для розробників прикладних програмних засобів у фінансовій сфері. Автори також визначили кілька перспективних напрямків для майбутніх досліджень, включаючи застосування ШІ та МН в ціноутворенні активів, дослідження впливу цих технологій на розвиток фінтех-сектору, а також використання ШІ та МН для виявлення фінансового шахрайства. Ці напрямки відображають зростаючу потребу у більш складних та ефективних інструментах аналізу та прийняття рішень у фінансовій сфері. Таким чином, дане дослідження є цінним ресурсом для розуміння поточного стану та майбутніх напрямків розвитку на перетині фінансів, штучного інтелекту та машинного навчання.

У контексті прогнозування фондового ринку методами машинного навчання варто розглянути всебічний аналіз 138 наукових статей, опублікованих з 2000 по 2019 рік [42]. Дослідники виявили, що найбільш досліджуваними ринками були США та Азія, з особливим фокусом на індекс S&P 500. У ході аналізу було ідентифіковано 2173 унікальні змінні, що використовуються для прогнозування, серед яких технічні індикатори виявилися найпоширенішими. Щодо методів машинного навчання, автори встановили, що штучні нейронні мережі, метод опорних векторів та нечітка

логіка є найпопулярнішими підходами. Примітно, що в останні роки спостерігається зростання використання методів глибокого навчання. Для оптимізації параметрів моделей часто застосовуються генетичні алгоритми, тоді як метод головних компонент (PCA) та вейвлет-перетворення широко використовуються для вилучення ознак. Автори також відзначили зростаючу тенденцію до використання текстових даних, таких як новини та дописи в соціальних мережах, для прогнозування тенденцій і волатильності фондового ринку. Для аналізу цих даних застосовуються методи обробки природної мови, аналізу настроїв та тематичного моделювання. Серед найбільш поширених змінних для прогнозування автори виділяють технічні індикатори (наприклад, ціна закриття, об'єм торгів, ковзні середні (Moving Averages), RSI, MACD, фундаментальні показники (P/E, EPS), макроекономічні показники та індикатори настроїв ринку. Особливо підкреслюється важливість аналізу настроїв ринку. Автори відзначають зростаючу тенденцію використання текстових даних, таких як фінансові новини, повідомлення в соціальних мережах і корпоративні оголошення для прогнозування динаміки фондового ринку. Зокрема, дослідники виділяють кілька ключових підходів до аналізу настроїв: класифікація тексту на позитивний, негативний або нейтральний; використання спеціалізованих словників настроїв та застосування методів машинного навчання для класифікації настроїв. Важливо відзначити, що ефективність цих методів часто перевіряється шляхом інтеграції отриманих показників настроїв з традиційними технічними та фундаментальними індикаторами. Автори підкреслюють, що включення аналізу настроїв може значно покращити точність прогнозування, особливо в контексті короткострокових прогнозів і прогнозування напрямку руху ринку.

Інший всебічний огляд літератури [43], що стосується прогнозування фінансових ринків на основі новин, використовуючи методи машинного навчання та аналізу текстів, фокусується на методах прогнозування фондових ринків через аналіз новинних текстів, які впливають на коливання цін акцій.

Автори систематизували дослідження, проведені в період з 2015 по 2022 рр., що застосовували різні моделі машинного навчання та методи обробки тексту, включно з такими методами, як Word2Vec, GloVe та моделі на основі трансформерів, зокрема BERT. Стаття також охоплює аналіз як структурованих, так і неструктурованих даних для підвищення точності прогнозування. Окрему увагу приділено аналізу настроїв (Sentiment Analysis), який виявився одним із ключових аспектів у прогнозуванні. Автори підкреслюють, що поєднання інформації з новин з історичними даними про ціни акцій суттєво покращує результати моделей. Використовувалися як лексиконні підходи до аналізу тональності, так і методи на основі машинного навчання, серед яких домінували моделі штучних нейронних мереж, такі як LSTM і CNN. Дослідження також виявило, що застосування глибоких нейронних мереж, зокрема LSTM, є найефективнішим для обробки послідовностей новинних даних і прогнозування змін на ринку. Щодо джерел даних, більшість досліджень використовували новинні джерела, такі як Reuters, Bloomberg та Yahoo Finance. Автори акцентують на тому, що збір новинних текстів є дорогим та ресурсоємним процесом, однак існують доступні бази даних, які спрощують цей процес. Крім того, дослідження вказують на обмеження в обсязі використовуваних даних: більшість моделей працюють із наборами даних, що містять менше ніж 100 тисяч записів, хоча новіші моделі глибокого навчання здатні працювати з більшими обсягами даних і потенційно покращувати результати прогнозування. Загалом дослідження ще раз підкреслює важливість обробки тексту, аналізу настроїв та використання нейронних мереж глибокого навчання для підвищення точності прогнозів.

У дослідженні впливу штучного інтелекту і загальної цифровізації на фінансові ринки та економіку природних ресурсів [44] розглянуто широкий спектр питань, включаючи вплив ШІ на викиди вуглекислого газу та сталий розвиток, прогнозування цін на сировинні товари, вплив цифрових фінансів на

ринки ресурсів, а також застосування ІІІ для оптимізації використання ресурсів та підвищення ефективності різних галузей економіки. Методологія досліджень включала різноманітні підходи, від класичних економетричних методів аналізу панельних даних до сучасних технік машинного навчання та глибокого навчання з підкріпленням. Зокрема, були використані штучні нейронні мережі (ANN), просторові економетричні моделі, нелінійні авторегресійні моделі з розподіленим лагом (NARDL), а також методи бібліометричного аналізу. Такий міждисциплінарний підхід дозволив отримати всебічне розуміння досліджуваних явищ та їх взаємозв'язків. Результати досліджень демонструють значний потенціал ІІІ та цифрових технологій у вирішенні глобальних проблем сталого розвитку. Зокрема, було виявлено, що впровадження ІІІ та цифровізація позитивно впливають на ефективність використання ресурсів та зниження викидів CO₂. Дослідження також показали, що ІІІ підвищує інноваційну ефективність компаній та може ефективно прогнозувати ціни на сировинні товари. Крім того, було встановлено, що розвиток інтернету сприяє зниженню викидів вуглецю в містах, а використання ІІІ в сільському господарстві підвищує його сталість. Важливо відзначити вплив цифрових фінансів на ринки природних ресурсів та потенціал ІІІ для оптимізації прийняття рішень у підприємницьких проєктах. Загалом, огляд авторів [44] свідчить про трансформаційний потенціал ІІІ та цифрових технологій у контексті управління природними ресурсами та досягнення Цілей сталого розвитку ООН. Однак, дослідження також вказують на необхідність подальшого вивчення довгострокових наслідків впровадження цих технологій і розробки відповідних політик для максимізації їх позитивного впливу на економіку та навколишнє середовище.

У сучасній фінансовій галузі все більшого значення набувають методи машинного навчання для оптимізації інвестиційних портфелів. Недавнє дослідження [45] порівнює ефективність різних підходів до побудови портфеля, включаючи традиційні методи та передові алгоритми машинного

навчання. Автори розглянули 10 різних методів, серед яких традиційні підходи (рівноважний інвестиційний портфель, максимізація коефіцієнта Шарпа, мінімальна дисперсія), статистичні методи (ієрархічний розподіл ризику, метод головних компонент, експоненціальне згладжування Холта) та методи машинного навчання (глибоке навчання та навчання з підкріпленням). Результати показали, що метод навчання з підкріпленням демонструє найкращі показники за кумулятивною дохідністю та коефіцієнтом Шарпа в обох експериментах. Глибоке навчання показало хороші результати на зростаючому ринку В'єтнаму, але гірші – на більш стабільному ринку США. Традиційні методи оптимізації портфеля стабільно показували нижчі результати порівняно з методами машинного навчання. Важливо відзначити відмінності між глибоким навчанням та навчанням з підкріпленням. Глибоке навчання базується на використанні глибоких нейронних мереж і фокусується на розпізнаванні патернів у статичних даних. Навчання з підкріпленням, натомість, моделює процес прийняття рішень у динамічному середовищі, де агент навчається через взаємодію з середовищем, отримуючи винагороди за правильні дії. Ця особливість дозволяє методу навчання з підкріпленням краще адаптуватися до змінних ринкових умов, що підтверджується результатами дослідження. Загалом, робота підтверджує потенціал використання передових алгоритмів машинного навчання, особливо навчання з підкріпленням, для підвищення ефективності управління інвестиційними портфелями. Ці методи демонструють здатність адаптуватися до різних ринкових умов та підтримувати якісно диверсифікований портфель, що є ключовим фактором успішного інвестування.

Автори статті “From fundamental signals to stock volatility: A machine learning approach” вивчали ефективність застосування методів машинного навчання для прогнозування волатильності акцій на основі фундаментальних показників компаній на фондовому ринку. Автори використали дані за період 2004-2019 років, що включають 54 фундаментальні характеристики компаній.

Для побудови агрегованих сигналів фундаментального ризику (FRS) були застосовані різні алгоритми машинного навчання, включаючи звичайний метод найменших квадратів (OLS), метод часткових найменших квадратів (Partial Least Squares, PLS), Elastic Net (ENet), випадковий ліс (RF) і нейронну мережу прямого поширення (FFN). Результати дослідження показали, що нелінійні моделі машинного навчання, особливо нейронні мережі, перевершують лінійні методи у прогнозуванні волатильності акцій. Агреговані сигнали фундаментального ризику продемонстрували значну прогностичну силу щодо майбутньої волатильності акцій. Найважливішими характеристиками для прогнозування волатильності виявилися показники, пов'язані з прибутковістю та інвестиціями компаній. Автори також виявили, що акції з високою прогнозованою волатильністю зазвичай мають нижче зростання, вищі інвестиції та більші нематеріальні активи. Важливо зазначити, що дане дослідження фокусувалося саме на прогнозуванні волатильності акцій, а не їх цін. Волатильність визначалась як логарифм суми квадратів щоденних відсоткових прибутків акції за місяць. Автори використали нейронну мережу прямого поширення з чотирма шарами, яка показала найкращі результати серед усіх досліджених моделей. Дослідження демонструє ефективність методів машинного навчання для прогнозування волатильності на основі фундаментальних показників компаній.

У сучасній фінтех галузі значна увага також приділяється прогнозуванню ризику обвалу цін на акції з використанням методів машинного навчання. Дослідження, проведене у 2024 році [46], демонструє, що алгоритми машинного навчання, зокрема нейронні мережі прямого поширення (FFN) та випадковий ліс (RF), значно перевершують традиційні економетричні методи у прогнозуванні цього ризику. У дослідженні використано широкий спектр методів, включаючи метод головних компонент (PCA), частковий метод найменших квадратів (PLS), LASSO, гребневу регресію (RIDGE) та еластичну мережу (Enet) та порівняно їхню ефективність

з методом найменших квадратів (OLS). Результати дослідження показують, що нелінійні моделі, особливо FFN, досягають найвищих показників R^2 у прогнозуванні поза вибіркою. Важливо відзначити, що ефективність моделей машинного навчання особливо висока для державних підприємств і в періоди низької економічної та політичної невизначеності. Аналіз також виявив, що основними факторами, які визначають ефективність прогнозування, є характеристики прибутковості компаній і співвідношення їх вартості до зростання. Дослідження також демонструє здатність моделей машинного навчання виявляти ознаки маніпуляцій із бухгалтерською звітністю та агентських конфліктів, які впливають на ризик обвалу цін. Крім того, автори підтверджують, що низька інформативність цін на акції та зняття обмежень на короткі продажі пов'язані з вищим ризиком обвалу цін.

Автори дослідження “Machine-learning stock market volatility: Predictability, drivers, and economic value” [47] провели комплексний аналіз ефективності методів машинного навчання для прогнозування волатильності фондового ринку США. Автори порівняли різні ML методи, включаючи регуляризаційні підходи (LASSO, Ridge, Elastic Net), методи на основі дерев рішень (Random Forest, Gradient Boosted Regression Trees) та нейронні мережі (NARX), з традиційною гетерогенною авторегресійною моделлю (HAR). Дослідження фокусувалося на прогнозуванні реалізованої волатильності індексу S&P 500 на різних часових горизонтах. Результати показали, що ML методи перевершують HAR модель на короткому горизонті прогнозування (1 місяць), але не демонструють переваг на довгих горизонтах (6 і 12 місяців). Серед ML методів найкращі результати показали регуляризаційні підходи та нейронні мережі. Однак, економічна цінність прогнозів волатильності, отриманих за допомогою ML методів, виявилася несуттєво вищою порівняно з бенчмарк-моделлю HAR. Автори також виявили, що якість предикторів має більше значення для успішного прогнозування, ніж довжина часового ряду. Аналіз факторів, що впливають на волатильність, показав, що на коротких

горизонтах прогнозування ключову роль відіграють фінансові та макроекономічні показники невизначеності. На довших горизонтах більшого значення набувають змінні, пов'язані з економічним циклом та фінансовим ринком. Важливим висновком дослідження є те, що вибір бенчмарк-моделі суттєво впливає на оцінку ефективності ML методів. При використанні авторегресійної (AR) моделі як бенчмарка, ML методи показали кращі результати на всіх горизонтах прогнозування.

При розробці Robo-Advisor систем критично важливим є ефективне опрацювання великих масивів фінансових даних для прийняття інвестиційних рішень. Однак проблема відсутніх даних може значно ускладнювати процес автоматизованого прийняття рішень і потенційно призводити до неоптимальних інвестиційних стратегій. Дослідження методів обробки відсутніх даних стає особливо актуальним при використанні методів машинного навчання в Robo-Advisor системах, оскільки традиційний підхід видалення спостережень з пропущеними даними може призвести до втрати занадто великої частки доступних даних. В одному з досліджень розглядається проблема обробки відсутніх даних при застосуванні методів машинного навчання для прогнозування дохідності акцій [48]. Автори аналізують структуру та походження відсутніх даних у 159 предикторах дохідності акцій, порівнюють різні методи імпутації та оцінюють їхній вплив на прогнозування дохідності акцій різними алгоритмами машинного навчання. Було досліджено велику кількість методів імпутації, включаючи крос-секційний ЕМ алгоритм (Expectation-Maximization), просту імпутацію середнім значенням, ЕМ на залишках AR1 (авторегресійної моделі першого порядку) моделі, практичний ЕМ для ймовірнісного методу головних компонент (PCA). Для прогнозування застосовуються такі методи як регресія на головних компонентах (PCR), масштабована PCR, градієнтний бустинг дерев рішень (GBRT) і нейронні мережі з різною архітектурою. Ключовим результатом дослідження є висновок про те, що проста імпутація середнім значенням показує результати,

подібні до більш складних методів імпутації, при прогнозуванні дохідності акцій. Автори пояснюють це низькою кореляцією між предикторами та блочною структурою відсутніх даних, що обмежує інформативність спостережуваних даних для імпутації. Крім того, складні методи імпутації можуть вносити додатковий шум, особливо для акцій малої капіталізації, що може призводити до гірших результатів прогнозування. Автори рекомендують використовувати просту імпутацію середнім значенням для обробки відсутніх даних у дослідженнях прогнозування дохідності акцій з використанням машинного навчання. Дослідження також демонструє, що нейронні мережі показали найкращі результати прогнозування дохідності серед усіх розглянутих методів.

Гіпотеза ефективного ринку (ЕМН), вперше сформульована Юджином Фамою у 1970 році, стверджує, що фінансові ринки є "інформаційно ефективними". Це означає, що ціни на активи, такі як акції, вже відображають всю доступну інформацію, і тому їх неможливо систематично передбачати або "перемагати" ринок у довгостроковій перспективі. Згідно з цією теорією, як тільки нова інформація стає доступною, вона майже миттєво відображається у цінах на активи. Наприклад, якщо компанія оголошує про несподівано високі квартальні прибутки, ціна її акцій зазвичай швидко зростає, відображаючи цю нову інформацію. Це робить неможливим для інвесторів отримувати надприбутки на основі цієї інформації, оскільки ринок вже "врахував" її у ціні. Таким чином, згідно з ЕМН, спроби прогнозувати майбутні ціни на основі історичних даних або публічно доступної інформації не повинні систематично приносити результати кращі, ніж випадковий вибір. У своєму дослідженні, що розглядає ефективність базових алгоритмів машинного навчання для прогнозування напрямку руху цін на фінансові інструменти [49], автори розглянули чотири широко використовуваних методи машинного навчання: штучні нейронні мережі (ANN), метод опорних векторів (SVM), випадковий ліс (RF) та наївний байєсівський класифікатор (NB). Дослідження охоплює як

розвинені ринки, так і ринки, що розвиваються, аналізуючи дані 10 найбільших за капіталізацією акцій та основного індексу з кожного ринку. Методологія дослідження базується на використанні технічних індикаторів як вхідних змінних для моделей машинного навчання. Автори розглядають різні форми представлення цих індикаторів: безперервні значення, дискретні тренди та їх комбінацію. Важливим аспектом дослідження є порівняння результатів прогнозування для поточного та наступного дня, з використанням строгого розділення даних для уникнення проблеми "зазирає в майбутнє" (data snooping bias). Результати дослідження показують значну розбіжність між прогнозуванням напрямку цін на поточний і наступний день. При прогнозуванні напрямку руху цін на поточний день всі моделі демонструють високу точність (80-100%), особливо при використанні дискретних форм технічних індикаторів. Однак, при прогнозуванні на наступний день, точність всіх моделей знижується до рівня випадкового вгадування (близько 50%). Важливо відзначити, що ця закономірність спостерігається як для розвинених ринків, так і для ринків, що розвиваються, що суперечить поширеному припущенню про більшу передбачуваність ринків, що розвиваються. Автори також досліджують вплив застосування порогового значення для зміни цін, прогнозуючи лише для днів із сильними трендами, але це не призводить до покращення результатів. Дослідження приходить до висновку, що базові алгоритми машинного навчання в їх стандартній формі неефективні для прогнозування напрямку руху цін на наступний день в реальних умовах торгівлі. Це дослідження надає вагомі докази на підтримку гіпотези ефективного ринку, демонструючи, що навіть сучасні методи машинного навчання не здатні точно передбачати рух цін на фінансових ринках. Автори рекомендують зосередитись на вдосконаленні базових алгоритмів та їх комбінуванні для покращення точності прогнозування.

У своєму дослідженні Шенг та ін. [50] представили підхід до прогнозування різких падінь цін на акції, використовуючи мультимодальні

дані та методи машинного навчання. Автори розробили комплексний фреймворк, який поєднує три типи даних: ринкові, графові та текстові. Ринкові дані включали традиційні технічні індикатори та описові показники. Графові дані представляли мережу взаємозв'язків між компаніями в межах галузі, оброблену за допомогою алгоритму Node2vec. Текстові дані були отримані шляхом аналізу настроїв новин, для чого автори розробили спеціальний фінансовий словник настроїв та обчислювали індекси позитивності та розбіжності для кожної новини. Дослідники порівняли ефективність різних алгоритмів машинного навчання, включаючи LightGBM, XGBoost, Random Forest, Logistic Regression та RUB. Модель LightGBM, навчена на мультимодальних даних, показала найкращі результати з Balanced Accuracy 75.85%. Особливу увагу автори приділили практичній застосовності моделі, запропонувавши новий підхід до оцінки її ефективності через створення інвестиційного портфеля на основі прогнозів. Цей портфель показав річну доходність 4,75%, що на 27,26% перевищило показники індексу CSI 300. Важливим результатом дослідження стало виявлення значущості графових даних, які виявилися другими за важливістю після ринкових. Це підкреслює важливість врахування взаємозв'язків між компаніями та галузевих особливостей при прогнозуванні ринкових ризиків. Автори також продемонстрували, що мультимодальний підхід перевершує моделі, які використовують лише один або два типи даних, як за точністю прогнозування, так і за стабільністю та прибутковістю сформованого на основі прогнозів портфеля.

У дослідженні, присвяченому проблемі прогнозування фондового ринку з використанням методів машинного навчання [51], автори зосереджуються на розробці методу Evaluated Linear Regression based Machine Learning (ELR-ML) для прогнозування цін акцій індексу S&P 500. Дослідження використовує дані з Yahoo Finance, аналізуючи такі параметри як ціна відкриття, ціна закриття, мінімальна та максимальна ціни, а також обсяг торгів. Методологія

дослідження базується на застосуванні лінійної регресії з оптимізацією параметрів методом градієнтного спуску. Автори використовують метод найменших квадратів для знаходження лінії найкращого наближення та оцінюють якість моделі за допомогою коефіцієнта детермінації (R-squared) та середньоквадратичної помилки (MSE). Особливістю запропонованого алгоритму є його здатність аналізувати взаємозв'язки між різними факторами, що впливають на динаміку фондового ринку. Результати дослідження демонструють, що модель ELR-ML досягла кращої точності прогнозування порівняно з базовою регресійною моделлю, показавши Train Score MSE=0,00106 (RMSE=0,03) та Test Score MSE=0,00875 (RMSE=0,09). Автори виявили сильну кореляцію між основними показниками цін акцій, але низьку кореляцію обсягу торгів з іншими показниками. Модель продемонструвала здатність відстежувати загальні тренди фондового ринку, проте мала труднощі з прогнозуванням під час фінансових криз. Дослідження підкреслює потенціал використання методів машинного навчання для прогнозування фондового ринку, одночасно вказуючи на складність цього завдання, особливо в періоди високої волатильності ринку.

Враховуючи загальну складність задачі оцінки інвестиційних ризиків, особливої уваги заслуговують дослідження, спрямовані на розробку інноваційних методів прогнозування фінансових ризиків. У цьому контексті розглянута робота, автори якої запропонували новий підхід до оцінки ризиків на прикладі вугледобувної галузі [52]. Автори запропонували підхід, що поєднує алгоритм оптимізації дрозофіл (Fruit Fly Optimization Algorithm, FOA) з нейронною мережею зворотного поширення (BPNN). Це дослідження є особливо актуальним в контексті зростаючої невизначеності на енергетичних ринках та потреби в ефективних інструментах оцінки ризиків для венчурних інвесторів. Методологія дослідження базується на комбінації сучасних технік машинного навчання та фінансового аналізу. Автори використали факторний аналіз для попередньої обробки фінансових показників, що дозволило

зменшити розмірність вхідних даних та підвищити стабільність нейронної мережі. FOA був застосований для оптимізації ваг та порогів BPNN, що значно покращило ефективність моделі порівняно з традиційними підходами. Результати дослідження демонструють високу ефективність запропонованої моделі. Досягнута точність прогнозування фінансових ризиків склала 95%, що перевершує показники інших алгоритмів, таких як SVM, ANN та GA. Модель також показала кращі результати за метриками MSE, MAE та RMSE. Особливо варто відзначити здатність моделі ефективно аналізувати динаміку фінансових показників, що має важливе значення для прийняття інвестиційних рішень в умовах високої волатильності.

У фінансовому ризик-менеджменті все частіше застосовуються методи машинного навчання для покращення точності оцінки ризиків. Автори дослідження [53] запропонували новий підхід до обчислення Value-at-Risk (VaR), названий "Encoded Value-at-Risk" (Encoded VaR). В основі методу лежить використання варіаційних автоенкодерів (VAE) - спеціального типу нейронних мереж, що належать до методів глибокого навчання. Основною метою дослідження було розробити модель, здатну точно оцінювати ринковий ризик без необхідності робити припущення щодо розподілу доходностей активів. Автори використали VAE для моделювання розподілу доходності портфеля, що дозволило вивчити структуру залежностей між активами та відтворити складні невідомі розподіли з характерними для фінансових даних "товстими хвостами". Методологія дослідження включала порівняння результатів Encoded VaR з дванадцятьма іншими методами оцінки VaR на даних з трьох різних ринків: S&P500, Лондонської фондової біржі (LSE) та Франкфуртської фондової біржі (FSE). Результати дослідження показали, що Encoded VaR демонструє конкурентоспроможні результати порівняно з іншими методами, особливо для портфеля FSE та при 95% довірчому інтервалі. Важливою перевагою запропонованого методу є його здатність збільшувати відношення сигналу до шуму у фінансових даних, зберігаючи при

цьому важливу інформацію. Крім того, модель продемонструвала гнучкість у налаштуванні та можливість адаптації до різних ринкових умов. Це дослідження робить внесок у розвиток методів оцінки фінансових ризиків, що поєднують переваги сучасного машинного навчання з традиційними підходами фінансового ризик-менеджменту. Воно відкриває нові перспективи для подальших досліджень у цій галузі та може мати важливе практичне застосування в управлінні фінансовими ризиками, зокрема в автоматизованих системах фінансового консультування.

Автори дослідження “How can we use artificial intelligence for stock recommendation and risk management? A proposed decision support system” [54] розробили та проаналізували персоналізовану систему рекомендацій акцій, яка враховує потреби та інтереси інвесторів. Авторами було досліджено три різних підходи до побудови рекомендаційної системи: k-найближчих сусідів (kNN), сингулярний розклад матриці (SVD) та пошук асоціативних правил (ARM). Для подолання проблем масштабованості та розрідженості даних було застосовано ієрархічну кластеризацію користувачів. Дослідники врахували часовий горизонт інвестування, розділивши користувачів на короткострокових, середньострокових та довгострокових трейдерів (рис. 1.2). Система також враховувала історію торгівлі та уподобання щодо акцій, оцінюючи їх на основі кількості придбаних акцій. Важливим аспектом була прибутковість попередніх інвестицій – для побудови системи рекомендацій використовувались дані користувачів із позитивною середньою нормою прибутку. Результати дослідження показали, що метод kNN продемонстрував найкращі показники точності прогнозування та класифікації. Системи з явними рейтингами перевершили системи з неявними відгуками. Автори також оцінили очікувану дохідність і вартість під ризиком (VaR) рекомендованих портфелів, що підтвердило прибутковість рекомендацій при мінімальних фінансових ризиках. Однак дослідники відзначили обмеження через відсутність детальної інформації про досвід інвесторів, їх толерантність

до ризику та характеристики акцій, що могло б покращити точність рекомендацій.

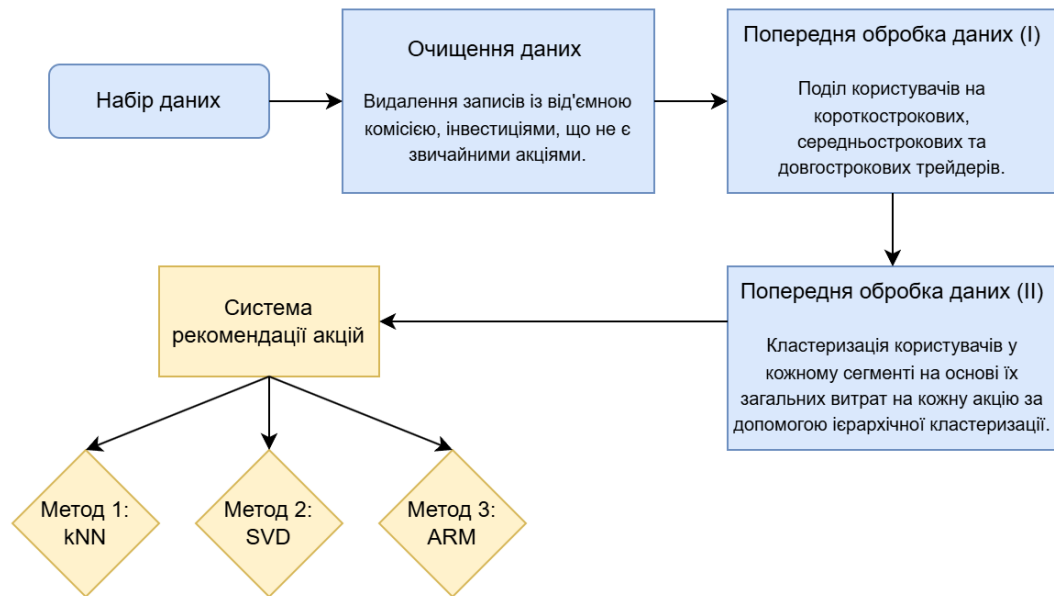


Рисунок 1.2. Блок-схема методології дослідження.

Джерело: підготовлено автором на основі [54].

Можливість прогнозувати не тільки ціни на конкретні фінансові інструменти, а й завчасно передбачати глобальні негативні тенденції на ринку загалом, надає перевагу як під час початкового формування інвестиційного портфелю, так і під час його ребалансування. Одне з досліджень [55] розглядає проблему прогнозування крахів фондового ринку за допомогою методів машинного навчання. Автори порівнюють ефективність простих одновимірних моделей і складніших багатовимірних моделей, використовуючи комплексний набір з 28 предикторів з п'яти найбільших країн Єврозони. Дослідження застосовує широкий спектр методів, включаючи логістичну регресію, метод опорних векторів (SVM), випадкові ліси, градієнтний бустинг і нейронні мережі. Методологія дослідження включає використання перехресної валідації для оцінки якості моделей, випадкової надвибірки для балансування класів у навчальних даних та ансамблевого навчання для підвищення стабільності прогнозів. Автори оцінюють моделі за допомогою статистичних метрик класифікації та економічних показників, таких як доходність інвестиційного портфелю. Результати дослідження

показують, що SVM-модель перевершує інші підходи за статистичними показниками прогнозування та забезпечує суттєву додану вартість для активних інвесторів. Важливим висновком є те, що нелінійність та інтерактивні ефекти відіграють ключову роль у прогнозуванні крахів фондового ринку. Дослідження також виявило, що важливість змінних-предикторів змінюється з часом, підкреслюючи необхідність використання багатовимірних моделей. Серед найважливіших предикторів виділяються тренди валютних курсів, доходність фондових, нафтових ринків і ринка золота, а також показники поточного ризику фондового ринку.

Різні методи машинного навчання для прогнозування часових рядів використовуються також і в більш вузькоспрямованих галузях. Наприклад, автори дослідження “Leveraging machine learning to forecast carbon returns: Factors from energy markets” [56] зосередились на прогнозуванні доходності національного вуглецевого ринку Китаю, використовуючи комбінацію традиційних економетричних методів і сучасних технік машинного навчання. Автори порівнюють ефективність різних методів прогнозування та визначають ключові фактори, що впливають на доходність вуглецевого ринку. Методологія дослідження включає застосування економетричних моделей, таких як ARMA (авторегресійна модель ковзного середнього) та GARCH (узагальнена авторегресійна умовна гетероскедастичність), а також методів машинного навчання: нейронної мережі зі зворотним поширенням помилки (BP), генетичного алгоритму для оптимізації BP (GA-BP) та випадкового лісу (RF). Особлива увага приділяється техніці RF, яка використовує ансамбль із 200 дерев прийняття рішень для підвищення точності та стійкості прогнозів. Результати дослідження демонструють, що модель випадкового лісу показує найвищу точність прогнозування серед усіх розглянутих методів. Цікаво, що деякі моделі GARCH з певними предикторами перевершили традиційно використовувану еталонну модель ARMA. Автори виявили, що найважливішими факторами для прогнозування доходності вуглецевого ринку

є індекс пошукових запитів щодо вуглецевих ринків, доходність нафти WTI та доходність фондового індексу HS300. Примітно, що міжнародні ціни на нафту виявилися важливішими для прогнозування, ніж внутрішні ціни на нафту в Китаї. Це також підкреслює потенціал методів машинного навчання, зокрема випадкового лісу, у прогнозуванні складних фінансових часових рядів.

У дослідженні “Machine learning portfolios with equal risk contributions: Evidence from the Brazilian market” [57] вивчається застосування методів машинного навчання для прогнозування дохідності акцій на бразильському фондовому ринку. Автор використовує широкий спектр моделей, включаючи лінійні методи (лінійна регресія, LASSO, ridge регресія), методи зменшення розмірності (регресія на головних компонентах, метод часткових найменших квадратів), ансамблеві методи (випадковий ліс, градієнтний бустинг) та нейронні мережі з різною архітектурою. Особлива увага приділяється нейронним мережам прямого поширення з кількістю прихованих шарів від одного до п'яти. На основі прогнозів моделей формуються різні інвестиційні стратегії, зокрема традиційні довго- і короткострокові (лонг-шорт) стратегії та їх модифікації з використанням підходу рівного розподілу ризику (Equal Risk Contribution, ERC). Автор також досліджує ефективність ансамблевих стратегій і мультистратегій, які комбінують прогнози або портфелі різних моделей машинного навчання. Результати дослідження показують, що всі розглянуті моделі машинного навчання здатні створювати портфелі, які перевершують ринковий індекс за дохідністю. Однак традиційні лонг-шорт стратегії виявляються обмежено ефективними через високу волатильність коротких позицій. Застосування підходу ERC значно покращує співвідношення ризику і дохідності. Найкращі результати демонструє мультистратегія ERC, яка комбінує портфелі різних моделей із рівним внеском у ризик, забезпечуючи вищу скориговану на ризик дохідність та значно меншу максимальну просадку порівняно з іншими стратегіями. Важливим спостереженням є також більша значимість фундаментальних показників для

прогнозування дохідності на бразильському ринку порівняно з розвиненими ринками.

У дослідженні, присвяченому практичному застосуванню глибокого навчання у фінансовій галузі [58], автори зосередилися на вивченні можливостей моделей глибокого навчання для прогнозування довгострокових цін на акції глобальних фондових індексів. На відміну від більшості подібних досліджень, які зазвичай фокусувалися на короткострокових прогнозах, автори поставили за мету оцінити ефективність різних архітектур нейронних мереж для передбачення щоденних цін на період до одного року. Дослідники застосували шість різних моделей глибокого навчання: глибокі нейронні мережі (DNN), рекурентні нейронні мережі (RNN), мережі з довготривалою короткочасною пам'яттю (LSTM), двонаправлені LSTM (Bi-LSTM), вентильні рекурентні блоки (GRU) та згорткові нейронні мережі (CNN). Кожна з цих архітектур має свої особливості та переваги в обробці часових рядів. Для забезпечення репрезентативності дослідження, автори використали дані п'яти глобальних фондових індексів: Nifty (Індія), Dow Jones Industrial Average (США), DAX (Німеччина), Nikkei 225 (Японія) та Shanghai Stock Exchange Composite Index (Китай). Результати дослідження виявили, що мережі LSTM демонструють найкращу ефективність у довгостроковому прогнозуванні цін на більшості досліджуваних індексів. Цікаво, що Bi-LSTM, незважаючи на свою більш складну архітектуру, не змогла перевершити звичайну LSTM, хоча й показала другий найкращий результат. Автори також відзначили, що CNN мали тенденцію до перенавчання на тренувальних даних і показували незадовільні результати на тестових даних. RNN продемонстрували гірші результати порівняно з LSTM, що дослідники пов'язують з проблемою зникаючого градієнта. GRU, хоча й вважаються обчислювально ефективнішими, показали нижчу точність прогнозування порівняно з LSTM та Bi-LSTM. Це дослідження підкреслює переваги LSTM для таких завдань і

може слугувати основою для подальших досліджень і розробки систем підтримки прийняття інвестиційних рішень.

Natural Language Processing (NLP) представляє собою міждисциплінарну галузь, що поєднує методи комп'ютерних наук, штучного інтелекту та лінгвістики для розробки систем, здатних розуміти, аналізувати та генерувати людську мову. Основними завданнями NLP є обробка та аналіз текстових даних, розпізнавання мовлення, машинний переклад, генерація текстів та інші задачі, пов'язані з природною мовою. Автори публікації “Intelligent risk management system for enhancing performance of stock market applications” [59] зосередились на розробці інтелектуальної системи, здатної аналізувати дані соціальних мереж для виявлення та оцінки потенційних ризиків на фондовому ринку. Дослідники застосували комплексний підхід, поєднуючи методи аналізу даних з передовими технологіями обробки природної мови. Методологія дослідження включала розробку спеціалізованих алгоритмів для аналізу ризиків, їх ідентифікації та оцінки. Автори створили фреймворк інтелектуальної системи управління ризиками (рис. 1.3), що складається з чотирьох ключових фаз: ідентифікація, оцінка, обробка та моніторинг ризиків. Особливу увагу було приділено розробці моделі NLP, здатної аналізувати дописи в соціальних мережах для класифікації ризиків, визначення їх типів та оцінки рівня загрози. Експериментальна частина дослідження базувалася на аналізі даних фондового ринку NASDAQ. Дослідники проаналізували понад 41000 дописів у соціальній мережі Twitter за шість місяців, досягнувши високих показників точності у різних аспектах аналізу ризиків. Зокрема, точність аналізу ризиків склала 82%, ідентифікації типів ризиків - 79%, а оцінки рівня ризиків - 68%. Ці результати демонструють потенціал технологій NLP для надання інвесторам інформації щодо потенційних ризиків на фондовому ринку на основі аналізу дописів користувачів у соціальних мережах.

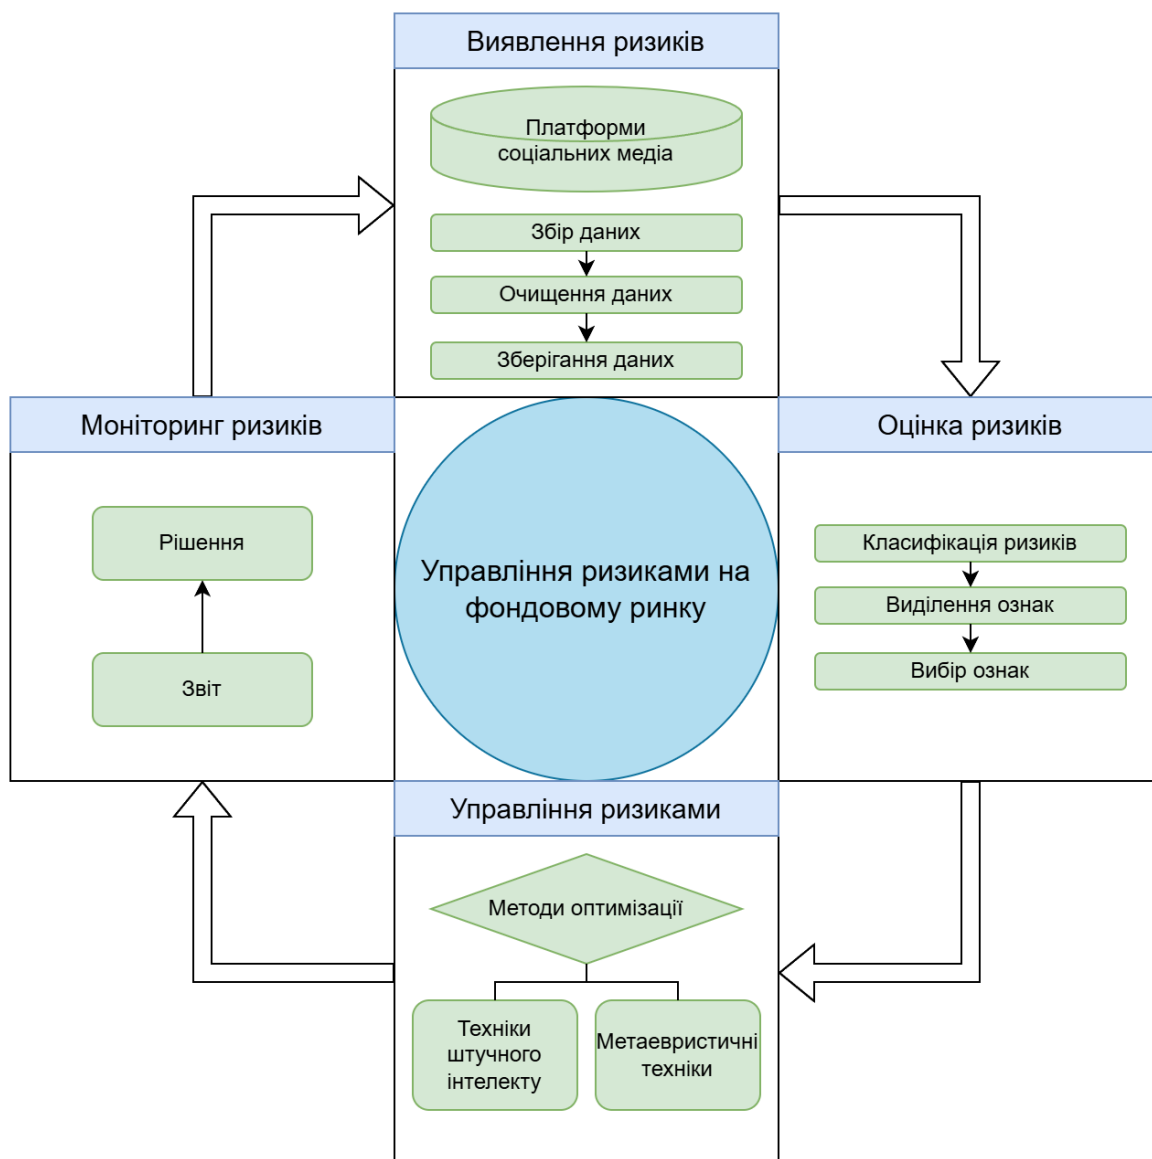


Рисунок 1.3. Система управління ризиками на фондовому ринку [59].

1.4 Прикладне застосування нейронних мереж глибокого навчання в системах персоналізованого фінансового консультування

Мова програмування Python найчастіше використовується для розробки, навчання та тестування моделей ML та DL, оскільки інструменти, що входять до стеку Python, пропонують більшу гнучкість при розробці та тестуванні ML моделей, ніж інше програмне забезпечення. Програмне забезпечення, що використовується для прогнозування структури інвестиційного портфеля, показано на рис. 1.4.




Рисунок 1.4. Програмне забезпечення/мови програмування для прогнозування структури портфеля (кількість досліджень у відповідній галузі) [38].

Одним із критичних зауважень щодо машинного навчання (ML) є те, що воно працює за принципом "чорної скриньки", через що важко зрозуміти, які предиктори сприяють точнішим прогнозам. Для дослідження важливості предикторів (ознак) для прогнозування, автори [60] проаналізували значущість ознак для методів ML за допомогою методу SHAP (SHapley Additive exPlanations). Значення SHAP кількісно оцінюють внесок кожного предиктора у передбачення результату, а також визначають, чи має цей предиктор позитивний або негативний зв'язок із результатом. При цьому розглядаються всі можливі комбінації доступних ознак, що використовуються для прогнозування результату, де граничний внесок предиктора визначається через порівняння середньої ефективності прогнозування моделі з цією ознакою та без неї [60].

У наукових дослідженнях із моделями глибокого навчання домінують RNN, DMLP та CNN, які значано переважають решту моделей [61]. При цьому модель RNN має декілька версій, серед яких LSTM, GRU тощо. Понад 70% RNN-моделей у проведених дослідженнях складали LSTM-моделі (рис. 1.5). Використання методів навчання з підкріпленням набуває все більшої популярності в задачах, пов'язаних із оптимізацією інвестиційних портфелів,

завдяки своїй здатності приймати рішення, спостерігаючи за навколишнім середовищем.




Рисунок 1.5. Розподіл DL моделей за частотою згадування (перша колонка - загальна кількість, друга колонка - за 2018-2020 pp.) [61].

У дослідженні “The applications of artificial neural networks, support vector machines, and long-short term memory for stock market prediction” [62] було проведено комплексний аналіз застосування трьох методів машинного навчання для прогнозування цін на фондовому ринку: штучних нейронних мереж (ANN), методу опорних векторів (SVM) та довготривалої короткочасної пам'яті (LSTM). Автори розглянули численні наукові роботи, в яких застосовувалися ці методи на різних фондових ринках, систематизуючи їх результати та ефективність. Результати дослідження показали, що ANN демонструють високу точність прогнозування, досягаючи 99,9% при використанні даних тікерів (унікальних символів (або короткого коду), що використовується для ідентифікації фінансових інструментів). Найефективнішими виявилися моделі з конфігурацією 5:21:21:1, що включає 5 вхідних нейронів, 2 приховані шари по 21 нейрону та 1 вихідний нейрон. SVM, у свою чергу, показав базову точність на рівні 60-70%, але його ефективність значно підвищувалася при застосуванні гібридних моделей,

зокрема з використанням генетичних алгоритмів. LSTM мережі, хоча і є підвидом ANN, були виділені авторами в окрему категорію через їх специфічну архітектуру та особливу ефективність у роботі з часовими рядами. Дослідження підтвердило, що LSTM перевершують інші методи у прогнозуванні часових рядів фондового ринку завдяки їх здатності враховувати довгострокові залежності в даних. Автори дослідження підкреслюють, що всі три розглянуті методи є ефективними для прогнозування цін акцій, проте LSTM мають певну перевагу в аналізі часових рядів фондового ринку.

У сучасних дослідженнях прогнозування трендів фондового ринку все більшу увагу привертають методи глибокого навчання. Зокрема, в одній із наукових робіт автори запропонували модель PLSTM-TAL (Peerhole Long Short-Term Memory with Temporal Attention Layer) для прогнозування напрямку руху фондових індексів [63]. Дослідники проаналізували щоденні дані чотирьох провідних світових фондових індексів: S&P 500 (США), FTSE (Великобританія), SSE Composite (Китай) та Nifty 50 (Індія) за період з 2005 по 2022 рік. Модель PLSTM-TAL представляє собою гібридну архітектуру, що поєднує модифіковану версію LSTM з "peerhole" з'єднаннями та шар темпоральної уваги (TAL). Ця комбінація дозволяє ефективно обробляти довгострокові залежності в часових рядах і фокусуватися на найбільш релевантних часових паттернах. Важливою особливістю запропонованого підходу є інтеграція методів попередньої обробки даних, таких як ансамблева емпірична декомпозиція мод (EEMD) для зменшення шуму та контрактивний автоенкодер (CAE) для ефективного вилучення ознак. Додатково для оптимізації гіперпараметрів моделі було застосовано Байєсівську оптимізацію. Результати дослідження показали, що модель PLSTM-TAL демонструє вищу ефективність порівняно з базовими моделями, такими як CNN, LSTM, SVM та RF, за більшістю метрик на всіх досліджуваних наборах даних. Точність прогнозування досягла 96% для фондового ринку

Великобританії, 88% для Китаю та 85% для ринків США та Індії. Цікаво відзначити, що фондові ринки Великобританії та Китаю виявилися більш передбачуваними, ніж ринки США та Індії. Дослідження також підкреслює важливість врахування довгострокових залежностей та темпоральних патернів (повторюваних закономірностей) при прогнозуванні трендів фондового ринку.

Одним із перспективних напрямків розробки ефективних методів управління інвестиційними портфелями є створення гібридних систем, які поєднують методи відбору акцій та оптимізації портфеля. Прикладом такого підходу є дослідження [64], в якому запропоновано гібридну систему на основі глибокого навчання та багатоцільової оптимізації. Ключовим елементом запропонованої системи є модель CNN-BiLSTM, яка використовується для прогнозування тенденцій акцій. CNN-BiLSTM – це гібридна архітектура нейронної мережі, яка поєднує в собі дві потужні технології глибокого навчання: згорткову нейронну мережу (CNN) та двонаправлену LSTM мережу. Модель аналізує такі показники як ціна закриття, обсяг торгів, тижневий коефіцієнт оборотності та тижнева прибутковість, що дозволяє класифікувати акції за їх потенціалом зростання. Автори демонструють, що CNN-BiLSTM перевершує традиційні методи машинного навчання та інші нейронні мережі у точності прогнозування. Для оптимізації портфеля дослідники розробили п'ятицільову модель, яка враховує середнє значення, дисперсію, асиметрію, ексцес та відстань до дефолту. Ця модель вирішується за допомогою покращеного алгоритму NSGA-III з хаотичним відображенням. Такий підхід дозволяє знаходити оптимальні ваги активів у портфелі, балансуючи між прибутковістю та різними аспектами ризику. Автори проводять порівняння з класичними, генетичними та метаевристичними портфельними стратегіями, а також виконують аналіз чутливості та обчислювальної ефективності. Результати показують, що гібридна система демонструє вищу прибутковість і нижчий ризик порівняно з іншими стратегіями, зберігаючи ефективність як на зростаючому, так і на спадаючому ринку. Загалом дослідження демонструє

важливість комплексного підходу до управління інвестиційним портфелем, який може бути застосований не лише до конкретного індексу акцій, але й до ширшого спектру фінансових інструментів. Це відкриває перспективи для подальших досліджень у напрямку інтеграції додаткових факторів, таких як ринкові настрої та аналіз громадської думки, а також вдосконалення ефективності алгоритмів оптимізації.

У роботі [65] досліджується застосування алгоритмів машинного навчання у фінансовій інженерії для прогнозування показників фондового ринку NASDAQ. Автори ставлять за мету передбачити ефективність ринку, враховуючи різноманітні фактори, включаючи вплив різних джерел енергії - вітрової, гідро-, теплової, газової та ядерної. Для досягнення цієї мети вони використовують низку передових методів машинного навчання: адаптивний LASSO (ALasso), Elastic Net (Enet), штучну нейронну мережу (ANN), згорткову нейронну мережу (CNN) та мережу з довготривалою короткостроковою пам'яттю (LSTM). Дослідники аналізують щомісячні дані цін акцій NASDAQ і виробництва електроенергії в США з різних джерел за період з січня 2001 по вересень 2023 року. Для оцінки ефективності моделей використовуються метрики середньоквадратичної помилки (RMSE) та середньої абсолютної помилки (MAE). Результати дослідження показують, що LSTM демонструє найкращу точність прогнозування змін на фондовому ринку NASDAQ, маючи найнижчі значення RMSE (0,29) та MAE (0,239). Інші моделі (ALasso, Enet, ANN, CNN) показують схожі, але дещо гірші результати. Варто зазначити, що в роботі не надається детальної інформації про конкретні налаштування гіперпараметрів LSTM мережі або методи їх підбору. Відсутність цієї інформації є суттєвим обмеженням дослідження, оскільки ці деталі важливі для розуміння точної конфігурації моделі та можливості відтворення результатів. Незважаючи на це обмеження, дослідження демонструє потенціал глибокого навчання, особливо LSTM мереж, для прогнозування фінансових ринків. Ці результати можуть бути корисними в

процесі розробки Robo-Advisor системи при виборі моделей для прогнозування, хоча для повного розуміння та відтворення результатів необхідна додаткова інформація про архітектуру та налаштування моделей.

У сучасних дослідженнях з прогнозування фінансових ринків все частіше застосовуються гібридні підходи, що поєднують методи інтелектуального аналізу даних і глибокого навчання. Одним із таких підходів є метод, який комбінує пошук асоціативних правил (Association Rule Mining, ARM) з глибокими нейронними мережами для прогнозування цін на акції [66]. Основою запропонованого методу є багатовимірна модель довготривалої короткочасної пам'яті (Long Short-Term Memory, LSTM), яка враховує не лише історичні дані цільової компанії, але й дані пов'язаних із нею компаній, виявлених на етапі пошуку асоціативних правил. Дослідники провели експерименти на даних 30 найбільших індійських компаній з індексу NIFTY50 за період з 2015 по 2022 рік. Результати показали, що запропонований гібридний підхід перевершує традиційні методи машинного навчання, такі як LightGBM, CatBoost, N-Beats, GRU та одновимірна LSTM, демонструючи покращення точності прогнозування на 8-10%. Важливим аспектом дослідження є ефективність запропонованого методу у виявленні нелінійних залежностей і прогнозуванні різких змін у цінах акцій. Статистична значущість отриманих результатів була підтверджена за допомогою одностороннього парного t-тесту Стюдента. Візуалізація прогнозів продемонструвала, що модель добре відтворює як загальні тренди, так і короткострокові коливання цін акцій. Це дослідження підкреслює важливість врахування взаємозв'язків між різними фінансовими інструментами при розробці систем прогнозування фондового ринку.

У статті [67] розглядається проблема неефективності лінійних моделей оцінки активів у контексті китайського фондового ринку. Автори відзначають, що традиційні моделі, зокрема п'ятифакторна модель Фама-Френча, не враховують нелінійні залежності між ключовими факторами ринку, такими як

доходність, ринкова капіталізація, тощо. Для розв'язання цієї проблеми, було запропоновано використання моделі LSTM мережі, яка здатна навчатися на нелінійних структурах даних і враховувати довгострокову кореляцію фінансових показників. У дослідженні проведено емпіричне порівняння ефективності моделі LSTM із традиційною моделлю Фама-Френча. Модель LSTM значно перевершила лінійну модель за такими критеріями, як точність прогнозування (коефіцієнт детермінації R^2 для LSTM склав 0,83, тоді як для моделі Фама-Френча — 0,61) і результативність інвестиційних стратегій. Зокрема, річна дохідність довго- і короткострокової стратегії, побудованої на основі прогнозів LSTM, становила 37,72%, що значно перевищує результат стратегії на основі моделі Фама-Френча (17,15%). Це свідчить про те, що LSTM більш ефективно вловлює нелінійні зв'язки між ринковими факторами, що робить її корисним інструментом для прогнозування на фондових ринках із подібними характеристиками. Модель LSTM, використана в дослідженні, має чітко визначені технічні характеристики. Вона складається з одного прихованого шару з п'ятьма нейронами, що разом формують 108 параметрів. Для оптимізації моделі використовується метод стохастичного градієнтного спуску, а функції активації представлені сигмоїдною функцією (перетворює вхідні значення у діапазоні від 0 до 1) та гіперболічним тангенсом (перетворює вхідні значення у діапазоні від -1 до 1). Графіки зазначених вище функцій активації представлено на рис. 1.6. Окрім цього, автори зазначають, що використання простішої архітектури LSTM було ефективним для обробки фінансових даних і забезпечило кращі прогнози в порівнянні з лінійними моделями. Загалом, дослідження демонструє, що застосування глибокого навчання може значно покращити точність прогнозів на фінансових ринках, де спостерігаються нелінійні ефекти. Результати також підкреслюють важливість врахування довго- та короткострокових залежностей у фінансових даних, що стає можливим завдяки використанню LSTM моделей.




Рисунок 1.6. Графіки різних функцій активації.

Джерело: власна розробка автора.

У статті "Optimization of investment strategies through machine learning" [68] представлено стійку модель кількісного інвестування в акції, яка поєднує підходи машинного навчання з економічною доданою вартістю (Economic Value-Added, EVA) для оптимізації інвестиційних стратегій. Основна мета дослідження полягала у розробці моделі, здатної забезпечувати стабільні та значні інвестиційні прибутки за різних ринкових умов. У статті було застосовано два ключові компоненти: кількісний відбір акцій та алгоритмічну торгівлю. Для відбору цінних акцій автори використовували метод головних компонент (Principal Component Analysis, PCA) та характеристики EVA (Economic Value Added) – фінансовий показник, що відображає реальну економічну прибутковість компанії. Це дозволило ефективно відокремити перспективні акції на основі фінансових індикаторів і розробити портфель, здатний забезпечувати вищу за середньоринкову прибутковість. Алгоритмічна торгівля, як другий компонент моделі, включала використання методів машинного навчання, таких як LSTM мережі, а також технічних індикаторів MACD (Moving Average Convergence Divergence) і стохастичних індикаторів (Stochastic Indicators, SI). Це дало змогу точно прогнозувати тренди на ринку акцій і приймати обґрунтовані рішення щодо купівлі або продажу акцій. Основні результати дослідження продемонстрували, що модель на базі LSTM здатна найбільш точно передбачати майбутні значення акцій у порівнянні з іншими алгоритмами машинного навчання, що використовувалися в дослідженні. За результатами п'ятирічного тестування модель забезпечувала

стабільно високу прибутковість у всіх ринкових ситуаціях. Зокрема, портфель з використанням EVA показав значно вищу дохідність у порівнянні з портфелем без EVA. Це підкреслює значущість використання EVA як інструменту оцінки внутрішньої вартості підприємств у процесі відбору акцій. Автори також зазначають, що застосування машинного навчання дозволяє підвищити точність прогнозів і сприяє раціональному підходу до інвестування. Таким чином, модель, запропонована в дослідженні, є не лише ефективною у забезпеченні прибутковості, але й стійкою, оскільки демонструє стабільні результати в умовах зростання, падіння та нестабільності ринку.

У дослідженні “Predicting stock market trends with self-supervised learning” [69] запропоновано новий підхід до прогнозування тенденцій фондового ринку з використанням методів самоконтрольованого навчання. Автори запропонували фреймворк SMART (Stock MARKET Trends prediction framework), який включає модель S3E (Self-supervised Stock data Sequence Embedding) для кодування послідовностей даних про акції. Ключовою особливістю цього підходу є використання трансформерів і механізмів уваги для обробки часових рядів фінансових даних. SMART використовує три допоміжні завдання для самоконтрольованого навчання: SSDT (Sequence Sample Discrimination Task) для вивчення унікальних характеристик акцій, SPCJT (Stock Price Co-movements Judging Task) для аналізу кореляцій цінних рухів між акціями, та TVCJT (Trading Volume Co-movements Judging Task) для дослідження кореляцій об'ємів торгів. Ці завдання дозволяють моделі ефективно витягувати корисні ознаки з нерозмічених фінансових даних, що є ключовою перевагою самоконтрольованого навчання в контексті фінансового прогнозування. Експериментальні результати показали, що SMART перевершує традиційні методи та сучасні підходи в прогнозуванні тенденцій фондового ринку. На ринку А-акцій Китаю модель досягла точності 58.96% і F1-міри 52.77%, а на ринку NASDAQ - точності 57.64% і F1-міри 51.62%. Ці показники перевершують результати найближчого конкурента - моделі

THGNN (Temporal and Heterogeneous Graph Neural Network). Особливо важливо відзначити ефективність SMART під час фінансової кризи 2008 року, де модель показала кращі результати порівняно з ринковим індексом та іншими методами. При застосуванні в реальній торговій системі SMART покращила кумулятивну прибутковість на більш ніж 5% порівняно з THGNN, що підкреслює практичну значимість цього підходу для фінансової індустрії.

Автори іншого дослідження [70] запропонували метод оптимізації портфеля акцій, названий HGA-MT (Heterogeneous Graph Attention - Multi-Task). Цей метод спрямований на вирішення комплексної задачі вибору прибуткових акцій з урахуванням як потенційного прибутку, так і ризику. Автори застосували передові технології машинного навчання, зокрема гетерогенні графові нейронні мережі, механізми уваги та мультизадачне навчання, для моделювання складних взаємозв'язків між акціями та одночасного прогнозування їх прибутковості та ризику. Ключовою особливістю методу HGA-MT є використання гетерогенного графа для представлення різних типів відносин між акціями, включаючи ланцюжки поставок, володіння акціями та конкуренцію в галузі. Для обробки цієї складної структури автори застосували Graph Convolutional Networks (GCN) у поєднанні з механізмом уваги, що дозволило ефективно агрегувати інформацію з різних типів зв'язків. Часова складова фінансових даних була врахована за допомогою BiLSTM мережі, яка обробляла як кількісні індикатори, так і векторні представлення новинних заголовків. Експериментальні результати продемонстрували значну перевагу HGA-MT над існуючими методами. У задачі ранжування акцій метод показав покращення точності на 11,09% та показника MRR (Mean Reciprocal Rank) на 8,29%. З точки зору фінансової ефективності, HGA-MT досяг на 14,94% вищої сукупної прибутковості інвестицій (IRR), на 11,24% вищого коефіцієнта Шарпа та на 14,42% нижчого максимального просідання (MDD). Ці результати свідчать про здатність методу досягати вищих і стабільніших прибутків при

одночасному зниженні ризику інвестиційного портфеля. Важливо відзначити, що абляційний аналіз, проведений авторами, підтвердив ефективність кожного компонента запропонованої моделі. Це демонструє, що успіх HGA-MT базується на поєднанні різних технологій машинного навчання, які разом дозволяють більш точно моделювати складну динаміку фондового ринку.

Новий підхід до управління інвестиційним портфелем, що поєднує методи глибокого навчання з підкріпленням та аналізу часових рядів представлено у роботі [71], автори якої розробили алгоритм WCG-RL (Wavelet Coherence Graph Reinforcement Learning), який використовує мульти-графове представлення для відображення динамічних кореляцій між активами на різних часових масштабах. Ключовою інновацією є застосування вейвлет-когерентності (метод аналізу сигналів, який дозволяє виявити та виміряти взаємозв'язок між двома часовими рядами у часово-частотній області) для побудови ребер графів, що дозволяє враховувати як часові, так і частотні аспекти взаємозв'язків між ціновими рядами акцій. Алгоритм WCG-RL складається з декількох компонентів, включаючи графові згорткові нейронні мережі для обробки мульти-графового представлення та агент глибокого навчання з підкріпленням для прийняття рішень щодо розподілу активів. Експериментальні результати на китайському фондовому ринку показали, що запропонований метод перевершує існуючі підходи за такими показниками як сукупна дохідність, коефіцієнт Шарпа та максимальна просадка. Дослідження демонструє потенціал інтеграції методів обробки сигналів і машинного навчання для покращення стратегій управління інвестиційними портфелями в динамічних ринкових умовах.

У сучасному фінансовому світі, де ринки характеризуються високою волатильністю та ризиками, особливо у секторі нової енергетики, розробка ефективних інвестиційних стратегій набуває критичного значення. Одне з досліджень [72] пропонує інноваційний підхід до вирішення цієї проблеми шляхом створення комплексної системи прийняття фінансових інвестиційних

рішень. Ця система інтегрує три ключові компоненти: вибір портфеля акцій, прогнозування трендів і кількісну торгівлю. Методологія дослідження базується на використанні передових технологій і методів аналізу даних. Зокрема, для вибору оптимального портфеля акцій застосовується коефіцієнт Шарпа, який дозволяє оцінити співвідношення ризику та дохідності. Для обробки часових рядів фінансових даних використовується метод варіаційної модової декомпозиції (VMD), що дозволяє ефективно виділяти значущі компоненти з нестационарних сигналів. Прогнозування трендів здійснюється за допомогою двонаправленої вентильної рекурентної нейронної мережі (BiGRU), яка є вдосконаленою версією GRU і здатна обробляти послідовності даних в обох напрямках, враховуючи як минулий, так і майбутній контекст. Результати дослідження демонструють значну ефективність запропонованої системи. Експериментальна група акцій, обрана системою, показала в чотири рази вищу дохідність порівняно з контрольною групою. Модель VMD-BiGRU продемонструвала кращі результати прогнозування порівняно з простими моделями GRU чи LSTM. Крім того, застосування алгоритмічної торгівлі дозволило ефективно використовувати короткострокові ринкові можливості, забезпечуючи нижчий ризик і вищу дохідність. Дослідження підкреслює важливість динамічного підходу до управління портфелем, зокрема через періодичний перерахунок коефіцієнта Шарпа та коригування складу портфеля. Це дозволяє ефективно знижувати ризики в умовах мінливого ринку. Застосування методу VMD для декомпозиції вхідних даних значно покращує точність прогнозування, що є критичним фактором для прийняття обґрунтованих інвестиційних рішень. Автоматизована алгоритмічна торгівля, реалізована в системі, демонструє переваги у вигляді швидкої реакції на ринкові зміни та виключення емоційного фактора з процесу прийняття рішень.

У сучасних дослідженнях фінансових ринків все частіше застосовуються методи глибокого навчання для прогнозування поведінки акцій і формування інвестиційних портфелів. Одним із таких досліджень є

робота [73], яка фокусується на використанні глибокого навчання для вибору портфеля акцій та прогнозування їх поведінки на Торонтській фондовій біржі (TSE). Автор застосовує ряд передових методів машинного навчання, такі як LSTM нейронні мережі та Deep RankNet алгоритм. Для оптимізації гіперпараметрів моделей було використано генетичний алгоритм. Deep RankNet, що є ключовим елементом дослідження, представляє собою алгоритм глибокого навчання, розроблений спеціально для ранжування об'єктів, у даному випадку – акцій. Цей метод використовує глибоку нейронну мережу для навчання на парах акцій з відомою відносною прибутковістю, що дозволяє моделі ефективно ранжувати акції за їх потенційною майбутньою прибутковістю. Особливістю Deep RankNet є його здатність враховувати складні нелінійні взаємозв'язки між характеристиками акцій та фокусуватися на відносній, а не абсолютній прибутковості. Результати дослідження показують, що використання генетичного алгоритму для оптимізації гіперпараметрів покращило точність прогнозування на 40% порівняно з традиційним методом випадкового пошуку по сітці. Крім того, Deep RankNet продемонстрував кращі результати, ніж LSTM, з точки зору прибутковості та управління ризиками. Особливо цікавим є те, що всі стратегії Deep RankNet перевершили ринковий індекс, причому ця перевага була особливо помітною в період високої волатильності, викликаній пандемією COVID-19. Автор також досліджував вплив розміру портфеля на його ефективність, виявивши, що портфелі з меншою кількістю акцій ($k=3$) показали вищу прибутковість, але з більшим ризиком, тоді як портфелі з більшою кількістю акцій ($k=10$) забезпечили кращий баланс між прибутковістю та ризиком. Дослідження підкреслює потенціал методів глибокого навчання у фінансовому аналізі та управлінні портфелем, особливо в умовах високої ринкової волатильності. Дослідження також демонструє важливість оптимізації гіперпараметрів та вибору відповідної архітектури нейронної мережі для досягнення оптимальних результатів у прогнозуванні поведінки фінансових ринків.

У дослідженні [74] представлено систему алгоритмічної торгівлі, що поєднує прогнозування трендів акцій та оптимізацію портфеля. Автори пропонують метод для аналізу технічних індикаторів, заснованого на Pixel Graph Network (PGN), а також застосовують модель Mean-Conditional Drawdown at Risk (M-CDaR) для оптимізації портфеля. Для використання PGN мережі значення різних технічних індикаторів перетворюються у 2D зображення, де кожен піксель відповідає певному індикатору або його значенню, надалі отримані зображення аналізуються за допомогою PGN для прогнозування трендів акцій. Алгоритм складається з двох етапів: прогнозування тренду акцій та оптимізації портфеля. На етапі прогнозування відбувається підготовка даних, включаючи збір історичних даних OHLCV (Open, High, Low, Close, Volume - ціни відкриття, максимальна, мінімальна, закриття та обсяг торгів відповідно), розрахунок технічних індикаторів та їх відбір. Далі дані перетворюються у 2D зображення розміром 10x10 пікселів, які класифікуються моделлю PGN для генерації сигналів купівлі/продажу. На етапі оптимізації портфеля відбираються акції з прогнозованими сигналами купівлі, визначаються оптимальні ваги за допомогою моделі M-CDaR, і проводиться щоденне ребалансування з урахуванням транзакційних витрат. Ключові елементи запропонованої методології включають алгоритм розмітки даних "Continuous Trend Labeling" для створення збалансованого набору даних та ієрархічний відбір ознак для вибору найбільш інформативних індикаторів. Особливістю підходу є використання графової структури в PGN, що дозволяє враховувати просторові взаємозв'язки між різними показниками при прогнозуванні. Результати показали перевагу системи PGN+M-CDaR над іншими моделями. Вона продемонструвала середньорічну дохідність 112%, коефіцієнт Сортіно 10,78 (Sortino Ratio - міра безризикова дохідність/ризик, що враховує лише негативну волатильність) та коефіцієнт Шарпа 2.79, що свідчить про її здатність формувати прибуткові інвестиційні портфелі при ефективному управлінні ризиками.

Інше дослідження [75] присвячене застосуванню методів машинного навчання для прогнозування ліквідності на в'єтнамському фондовому ринку. Автори зосередили увагу на двох основних фондових біржах В'єтнаму - Фондовій біржі Хошиміна (HOSE) та Ханойській фондовій біржі (HNX) - за період з 2011 по 2019 рік. Для аналізу були використані сім показників ліквідності, включаючи спред котирувань (SPRD), відносний спред (RESPRD), ефективний спред (EFSPRD), обсяг торгів (VOL), вартість торгів (VAL), коефіцієнт оборотності (TO) та міру Аміхуда (AMIHU). Дослідники застосували три методи машинного навчання для прогнозування ліквідності: нейронну мережу прямого поширення (MLP), нейронну мережу з довготривалою короткочасною пам'яттю (LSTM) та лінійну регресію - класичний метод машинного навчання з учителем. Моделі були розроблені для прогнозування міри Аміхуда (AMIHU) на основі історичних значень та інших показників ліквідності, для оцінки якості моделей використовувалася середньоквадратична помилка (MSE). Результати дослідження показали, що модель LSTM досягла найнижчого значення MSE для обох бірж, демонструючи найвищу точність прогнозування. Для даних HOSE найкращі результати були отримані моделлю LSTM з чотирма прихованими шарами ($MSE = 0,0252$), а для даних HNX - також моделлю LSTM з чотирма прихованими шарами ($MSE = 0,0169$). Цікаво відзначити, що для даних HOSE значення MSE, досягнуте LSTM, було близьким до результату лінійної регресії, що вказує на переважно лінійні взаємозв'язки між змінними. Натомість для даних HNX обидві нейромережеві моделі (MLP і LSTM) показали нижчі значення MSE порівняно з лінійною регресією, що свідчить про наявність нелінійних взаємозв'язків. Автори підкреслюють, що результати їхнього дослідження можуть бути використані для розробки методів підтримки прийняття рішень на фондових ринках, зокрема для формування портфелів фінансових інструментів на основі прогнозування ліквідності. Однак вони також зазначають обмеження свого підходу, а саме прогнозування лише на один день вперед, і пропонують у майбутніх дослідженнях розробити

моделі для довгострокового прогнозування та застосувати подібний підхід до інших фондових ринків.

Автори статті “Six-factor asset pricing and portfolio investment via deep learning: Evidence from Chinese stock market” [76] зосередились на застосуванні моделі глибокого навчання для прогнозування руху цін акцій на китайському фондовому ринку. В статті представлено шестифакторну модель, що включає 5 факторів ціноутворення активів Фама-Френча (ринкова премія, розмір, вартість, прибутковість, інвестиції) та короткостроковий фактор імпульсу. Для прогнозування на основі цих факторів була застосована нейронна мережа LSTM (Long Short-Term Memory), ефективність якої порівнювалася з іншими методами машинного навчання, такими як GRU, RNN, XGBoost, ERT, SVM та логістична регресія. Аналіз проводився на даних 3316 акцій за період 2008-2021 рр. Результати дослідження показали, що шестифакторна модель LSTM перевершила інші методи у поясненні та прогнозуванні рухів цін акцій. Крім того, були виявлені статистично значущі ефекти розміру, прибутковості, інвестицій і короткострокового імпульсу на щоденному китайському ринку. Автори запропонували чотирьохетапний підхід для вибору акцій, які можна надійно прогнозувати. Особливу увагу в дослідженні було приділено розробці та тестуванню торгових стратегій на основі прогнозів моделі. Через відсутність ефективних інструментів для коротких продажів на китайському ринку акцій, автори зосередились лише на стратегіях довгих позицій. Були розглянуті три стратегії з різними порогами для відкриття позицій (60%, 65% і 70%), орієнтовані на інвесторів із різною схильністю до ризику. Крім того, були сформовані оригінальні та динамічні портфелі, де склад останніх оновлювався кожні півроку. Тестування стратегій проводився на out-of-sample даних з 1 січня 2020 по 31 травня 2021 року. Результати дослідження продемонстрували, що динамічні інвестиційні стратегії на основі прогнозів моделі значно перевершили ринковий бенчмарк (індекс HS300). При цьому стратегії з вищими порогами виконання (65-70%) показали кращі результати з

точки зору співвідношення ризику та доходності. Це дослідження підкреслює ефективність застосування глибокого навчання для прогнозування на основі класичних факторів ціноутворення та пропонує підходи до формування інвестиційних стратегій.

Здатність моделей глибокого навчання, зокрема таких архітектур як LSTM, вловлювати складні нелінійні залежності та довгострокові патерни у часових рядах фінансових даних зумовлює їх активне застосування у формуванні інвестиційних стратегій. Ці методи використовуються як для безпосереднього прогнозування цін, так і для аналізу неструктурованих даних, наприклад, настроїв інвесторів. У табл. 1.5 наведено узагальнення підходів і ключових результатів досліджень [16, 67, 76], що використовують методи глибокого навчання для вирішення завдань інвестиційного аналізу та управління портфелем.

Таблиця 1.5

**Застосування методів глибокого навчання
в завданнях формування інвестиційних стратегій**

Задача / Проблема	Методологія / Ключові техніки	Ключові результати	Релевантність для RA систем
Формування портфеля на основі колективного інтелекту та DL [16].	Аналіз настроїв (StockTwits), TF-IDF, LSTM для прогнозування цін, оптимізація ризик-дохідність.	Підхід перевершив ринкові індекси (DJIA, S&P 500). Демонструє ефективність поєднання колективного інтелекту та методів ML/DL.	Використання DL для аналізу неструктурованих даних (настрої інвесторів) і прогнозування цін для покращення якості портфельних рішень.
Подолання обмежень лінійних факторних моделей	LSTM мережа для моделювання нелінійних залежностей між ринковими	LSTM модель значно перевершила модель Фама-Френча за	DL моделі, зокрема LSTM, здатні вловлювати складні нелінійні

(Фама-Френча) [67].	факторами та доходністю.	точністю прогнозування (R^2 0,83 проти 0,61) та ефективністю інвестиційної стратегії (37,72% проти 17,15%).	залежності, що робить їх корисними для прогнозування та побудови стратегій.
Прогнозування руху цін акцій на основі фінансових факторів і фактор імпульсу [76].	Шестифакторна модель Фама-Френча у поєднанні з LSTM для прогнозування. Порівняння з GRU, RNN, XGBoost, ERT, SVM, LogReg.	Модель LSTM перевершила інші методи у поясненні та прогнозуванні рухів цін. Динамічні стратегії на основі LSTM значно перевершили бенчмарк.	LSTM модель є ефективним методом для прогнозування на основі класичних фінансових факторів, що дозволяє створювати прибуткові торгові стратегії.

У сучасних дослідженнях з фінансового прогнозування все більше уваги приділяється методам агрегації інформації з онлайн-спільнот. Одним із перспективних напрямків у цій галузі є розробка штучних прогнозів щодо ринків (Artificial Prediction Markets, APM), які дозволяють ефективно об'єднувати думки великої кількості користувачів для передбачення руху цін на фінансових ринках. Дослідження [77], що пропонує новий метод прогнозування руху цін акцій, базується на аналізі коментарів користувачів найбільшого китайського форуму про акції "GuBa" на платформі EastMoney. Автори зібрали та проаналізували майже 1,9 мільйонів коментарів, пов'язаних із 39 акціями, що входять до індексу Shanghai Stock Exchange 50 (SSE50), за період з 2016 по 2022 рік. Методологія дослідження включала використання сучасних технологій обробки природної мови, зокрема комбінованої моделі BERT-BiLSTM для аналізу настроїв у коментарях користувачів. На основі цього аналізу були створені штучні агенти-трейдери, які брали участь в імітаційному ринку з використанням механізму ціноутворення Logarithmic

Market Scoring Rule (LMSR). Автори порівняли ефективність свого методу з іншими підходами, такими як Prediction Poll, Hard Voting та Soft Voting, а також з неймережевими моделями BERT-NN. Результати дослідження показали, що запропонований метод Arti-PM перевершив інші підходи як за точністю прогнозування руху цін акцій, так і за прибутковістю модельованої торгової стратегії. Особливо важливо, що Arti-PM продемонстрував стабільно високі результати як у короткострокових, так і в довгострокових прогнозах, ефективно відфільтровуючи низькоякісні коментарі та надаючи більшу вагу думкам "трейдерів" з кращими історичними результатами. Дане дослідження відкриває нові перспективи для подальших досліджень у галузі поєднання методів машинного навчання та аналізу соціальних медіа для підвищення точності фінансових прогнозів.

За останні кілька років значно зросла кількість наукових публікацій, присвячених дослідженню ефективності використання великих мовних моделей (LLMs) для аналізу настроїв у фінансових новинах і прогнозування руху цін на акції. Автори одного з нещодавніх досліджень [78] зосередили увагу на порівнянні продуктивності моделей OPT (Open Pre-trained Transformers), BERT (Bidirectional Encoder Representations from Transformers), FinBERT та традиційного словника Лоурана-Макдональда. Дослідження базувалося на масштабному наборі даних, що включав понад дев'ятисот тисяч фінансових новин про компанії США за період з 2010 по 2023 рік. Результати дослідження продемонстрували значну перевагу передових мовних моделей над традиційними методами аналізу фінансових текстів. Зокрема, модель OPT показала найвищу точність у 74,4% при прогнозуванні руху цін акцій на основі аналізу настроїв у новинах. BERT і FinBERT також продемонстрували високу ефективність з точністю 72,5% та 72,2% відповідно. Натомість, традиційний словник Лоурана-Макдональда показав значно нижчу точність - лише 50,1%. Особливу увагу автори приділили практичному застосуванню отриманих результатів для створення інвестиційних стратегій. Вони розробили торгую

стратегію long-short на основі аналізу настроїв OPT, яка продемонструвала винятково високий коефіцієнт Шарпа – 3,05. За період з серпня 2021 по липень 2023 року ця стратегія принесла вражаючий прибуток у 355%, значно перевершивши традиційні ринкові портфелі, які показали зростання близько 1%. Ці результати підкреслюють потенціал використання передових мовних моделей для розробки ефективних інвестиційних стратегій на основі аналізу настроїв. Дане та інші подібні дослідження відкривають нові перспективи для інтеграції штучного інтелекту та LLM у фінансові ринки. Автори наголошують на необхідності подальших досліджень у цій галузі і водночас підкреслюють важливість розробки відповідних регуляторних політик для керування використанням AI у фінансовій сфері [78].

1.5 Роль алгоритмічних торгових стратегій та аналізу фінансових індикаторів в управлінні інвестиційним портфелем

Інвесторам необхідно регулярно оцінювати ефективність акцій, тому рекомендується тримати в середньому 7 активів у портфелі [79]. Більшість досліджень розглядають можливість використання 10 або менше видів акцій з 20 альтернатив для формування портфеля. Емпірично доведено, що портфель має найкращі показники з точки зору співвідношення ризику та дохідності, коли він складається з 7-18 акцій [80].

З фінансової точки зору, необхідно оцінювати ефективність моделей з точки зору реалізованого прибутку, дохідності або фінансового результату, а не залежати виключно від точності, RMSE та MAPE моделі. На рис. 1.7 представлено метрики для оцінки якості формування інвестиційного портфеля.

За останні кілька років такі фінансові інструменти як криптовалюти стали популярними завдяки неймовірному зростанню та падінню цін за короткий проміжок часу. Хоча прогнозування цін на криптовалюти з

використанням ML домінує, існують дослідження щодо алгоритмічних моделей торгівлі криптовалютами та побудови динамічного портфеля криптовалют. Деякі моделі навчаються з використанням комбінації фундаментальних і технічних індикаторів (рис. 1.8).

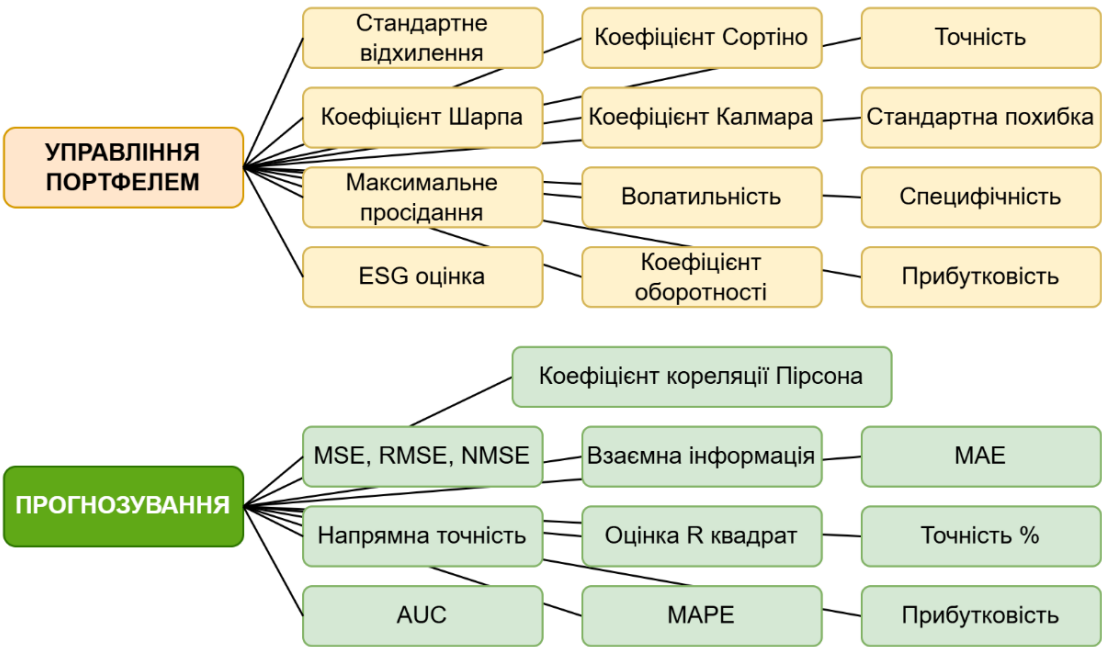


Рисунок 1.7. Показники ефективності управління портфелем та прогнозування частки його активів [38].



Рисунок 1.8. Розподіл методів для управління портфелем [38].

Алгоритмічні інвестиційні стратегії – це методи інвестування, де рішення про купівлю та продаж активів приймаються автоматично за допомогою комп'ютерних алгоритмів. Вони можуть використовуватися для автоматичного ребалансування інвестиційного портфеля, регулярно

коригуючи співвідношення активів відповідно до заданих параметрів і цілей інвесторів, що дозволяє підтримувати оптимальний рівень ризику та доходності без постійного ручного втручання.

У дослідженні [81] розглядається застосування методів машинного навчання для розробки алгоритмічних інвестиційних стратегій на глобальних фондових ринках. Автори зосередилися на аналізі ефективності різних моделей машинного навчання для прогнозування руху цін фондових індексів, порівнянні результатів алгоритмічних стратегій зі стратегією "купи і тримай", а також оцінці ефективності запропонованих моделей при зміні ринкових умов. Методологія дослідження базується на використанні п'яти технічних індикаторів (SMA, MACD, STOCH, RSI, WPR) як вхідних даних для восьми моделей машинного навчання, включаючи нейронні мережі, метод k-найближчих сусідів, дерева регресії, випадкові ліси, наївний байєсівський класифікатор, байєсівську узагальнену лінійну модель та метод опорних векторів з лінійним і поліноміальним ядром. Для оцінки ефективності стратегій застосовувалися різноманітні метрики, такі як сукупний середньорічний темп зростання (CAGR), річне стандартне відхилення, коефіцієнт Шарпа та максимальна просадка портфелю (MDD). Дослідження проводилося на основі щоденних цін High, Low, Close для індексів WIG20, DAX, S&P500 та шести індексів країн Центральної та Східної Європи за період 2002-2023 років. Результати дослідження показали, що алгоритмічні стратегії на основі машинного навчання перевершили пасивну стратегію "купи і тримай" за показниками доходності з урахуванням ризику для всіх досліджених індексів. При цьому найкращі результати в середньому продемонструвала модель Support Vector Machine з лінійним ядром (SVML). Важливо відзначити, що для різних індексів найбільш ефективними виявилися різні моделі, що вказує на відсутність універсального рішення для всіх ринків. Варто також зауважити, що в умовах зростаючого ринку жодна модель не змогла перевершити стратегію "купи і тримай", тоді як в умовах падаючого

ринку найкращі результати показали нейронні мережі та байєсівська узагальнена лінійна модель. Ці висновки підкреслюють важливість врахування ринкових умов при розробці та застосуванні алгоритмічних інвестиційних стратегій. Дане дослідження демонструє значний потенціал застосування методів машинного навчання для створення ефективних інвестиційних стратегій. Водночас, виявлена чутливість результатів до різних факторів вказує на необхідність ретельного тестування та оптимізації таких стратегій перед їх практичним застосуванням.

Важливим етапом формування інвестиційного портфелю є фундаментальний аналіз доступних для інвестування фінансових інструментів і формування портфелю з урахуванням правил диверсифікації та ризик-менеджменту. У роботі [82] представлено автоматизовану інвестиційну модель для отримання сигналів на покупку або продаж акцій на основі інформації про галузь, до якої відноситься відповідна компанія. Автори розробили комплексну систему, яка використовує статистичні методи для аналізу взаємозв'язків між акціями в межах однієї галузі. Методологія дослідження базується на розрахунку довірчих інтервалів цін акцій з використанням коефіцієнта кореляції Пірсона для оцінки взаємозв'язків між акціями компаній однієї галузі. Важливим елементом моделі є розрахунок фактора контролю ризиків на основі волатильності ціни, що використовується для визначення обсягу купівлі та моменту зупинки втрат (stop loss). Автори провели тестування моделі на історичних даних китайського фондового ринку з 2012 по 2022 рік. Результати дослідження показали високу ефективність запропонованої моделі. Середня річна прибутковість склала 11,1%, 64 із 70 проаналізованих підгалузей показали позитивну прибутковість. Модель продемонструвала універсальність застосування для більшості галузей і перевершила за прибутковістю основні фондові індекси за аналогічний період. Модель враховує всі транзакційні витрати (комісії), що підтверджує можливість її практичного використання. Дане дослідження робить внесок у

розвиток кількісних методів інвестування, пропонуючи ефективний підхід до використання інформації про галузь, до якої відноситься та чи інша компанія, для отримання стабільного прибутку на фондовому ринку з одночасним контролем ризиків.

В одному з нещодавніх досліджень, присвяченому розробці стратегій управління інвестиційними портфелями [83] розглядається застосування методів машинного навчання для ідентифікації фінансових коефіцієнтів на рівні секторів економіки, що можуть передбачати доходність акцій цих секторів. Автори використовували базу даних фінансових коефіцієнтів WRDS (Wharton Research Data Services) для 12 секторів економіки за класифікацією Фама-Френча, охоплюючи період з 1970 по 2021 роки. Методологія дослідження базується на застосуванні методу Elastic Net, який комбінує підходи LASSO та Ridge регресії для відбору найважливіших змінних і зменшення розмірності даних. Для оцінки ефективності моделі автори використали рекурсивне прогнозування поза вибіркою (out-of-sample (OOS) forecasting), розділивши дані на період навчання (1970 – 1989 pp.) та період тестування (1990 – 2021 pp.). Це дозволило більш реалістично оцінити ефективність моделі, імітуючи реальний процес прийняття інвестиційних рішень. На основі отриманих прогнозів були сформовані довгі (long) та довгі-короткі (long-short) портфелі. Результати дослідження показали, що Elastic Net виявив 30 різних прогнозних змінних для 12 секторів, з найчастішим вибором коефіцієнтів з категорій "Фінансова стійкість" та "Оцінка". Прогнозна здатність моделі була статистично значущою для 11 з 12 секторів, з показником ефективності моделі OOS (Out-Of-Sample) R^2 від 1,7% до 13,4%. Довгі портфелі (long portfolios – інвестиційні портфелі, в яких інвестор купує акції з очікуванням, що їхня ціна зросте), сформовані на основі прогнозів, продемонстрували вищу середню доходність (на 3-5%), вищі коефіцієнти Шарпа (0,72-0,79 проти 0,54 для ринку) та значні прибутки від інвестицій (до 114 разів початкової суми проти 30 для ринку) порівняно з ринковим

бенчмарком. Довгі-короткі портфелі (long-short portfolios – комбіновані портфелі, де інвестор одночасно займає довгі позиції в одних активах, тобто купує їх, і короткі позиції в інших, тобто продає їх без покриття) показали ще кращі результати з доходністю 6-8,4% вище ринку та значно нижчими максимальними просадками. Дане дослідження демонструє потенціал методів машинного навчання для ефективної ідентифікації фінансових коефіцієнтів, що можуть використовуватися для прогнозування доходності секторів і формування прибуткових інвестиційних стратегій.

У сучасних дослідженнях з оптимізації інвестиційних портфелів спостерігається тенденція до поєднання традиційних фінансових теорій із передовими методами штучного інтелекту. Зокрема, значну увагу привертають підходи, що інтегрують сучасну портфельну теорію (Modern Portfolio Theory) з алгоритмами глибокого навчання з підкріпленням (Deep Reinforcement Learning). Такі гібридні методи дозволяють враховувати як класичні принципи диверсифікації та управління ризиками, так і складні нелінійні залежності у фінансових даних. Одним із перспективних напрямків у цій галузі є використання алгоритму DDPG (Deep Deterministic Policy Gradient) для оптимізації портфеля в безперервному просторі дій [84]. Цей підхід дозволяє агенту навчатися оптимальної стратегії розподілу активів через постійну взаємодію з модельованим ринковим середовищем. Для підвищення ефективності такого підходу дослідники пропонують використовувати складні архітектури нейронних мереж, зокрема 3D згорткові мережі, які здатні обробляти багатовимірні фінансові дані. Важливим аспектом сучасних досліджень є інтеграція різних типів фінансової інформації в єдину модель. Зокрема, поєднання технічних індикаторів (таких як ковзні середні, RSI, MACD) з кореляційними матрицями активів дозволяє враховувати як короткострокові тренди, так і довгострокові взаємозв'язки між активами. Для ефективної обробки таких різномірних даних застосовуються методи тензорної декомпозиції, зокрема декомпозиція Такера, що дозволяє

зменшити розмірність вхідних даних без значної втрати інформації. Результати досліджень показують, що такі гібридні підходи здатні перевершувати як традиційні методи управління портфелем, так і окремі алгоритми машинного навчання за ключовими показниками ефективності, такими як коефіцієнт Шарпа, річна прибутковість і максимальна просадка. Крім того, ці методи демонструють кращу адаптивність до змінних ринкових умов, динамічно коригуючи структуру портфеля відповідно до поточних трендів.

Для підтримання інвестиційного портфелю в збалансованому стані традиційні фінансові експерти часто використовують міжгалузевий аналіз. В одному з досліджень на дану тему [85], автори вивчали можливість автоматизації використання високочастотних даних різних галузевих індексів для прогнозування волатильності загального фондового ринку, як змінюється прогностична здатність різних галузей з часом і в різних ринкових умовах, а також доцільність використання отриманих прогнозів волатильності на практиці. Методологія дослідження базується на використанні високочастотних 5-хвилинних даних для 10 галузевих індексів та індексу S&P 500 з вересня 2012 по грудень 2021 року. Автори застосовують різноманітні моделі машинного навчання, включаючи гетерогенну авторегресійну модель (HAR), метод регуляризації та відбору змінних Elastic Net, метод опорних векторів для регресії (SVR), нейронні мережі, випадковий ліс, адаптивний бустинг (AdaBoost), градієнтний бустинг дерев рішень (GBDT), екстремальний градієнтний бустинг (XGBoost) та легкий градієнтний бустинг (LightGBM). Результати дослідження показують, що більшість галузей містять цінну інформацію для прогнозування майбутньої волатильності загального ринку. Зокрема, охорона здоров'я, споживчі послуги та технологічні галузі виявилися найбільш інформативними для пояснення подальших коливань волатильності ринку. Автори виявили, що прогностична роль галузей змінюється з часом і залежить від горизонту прогнозування. Загалом,

дослідження демонструє, що включення галузевої інформації може значно покращити прогнози волатильності фондового ринку та принести економічні вигоди інвесторам, особливо на короткострокових і середньострокових горизонтах прогнозування.

Автори іншого дослідження [86] зосередилися на вивченні прогностичної сили фінансових індикаторів щодо доходності акцій на китайському фондовому ринку. В роботі використано широкий спектр із 62 фінансових індикаторів, розподілених на 10 категорій, включаючи грошовий потік, здатність до зростання, показники на акцію, структуру фінансування, здатність до погашення боргу, прибутковість, якість прибутку (фінансові індикатори, які оцінюють надійність і стійкість прибутку компанії), операційну здатність, розподіл дивідендів і відносну вартість. Це дозволило провести комплексний аналіз різних аспектів фінансової діяльності компаній. Методологія дослідження базується на застосуванні методів машинного навчання, зокрема лінійної регресії, еластичної мережі, випадкового лісу та нейронної мережі. Особливу увагу було приділено трьохшаровій нейронній мережі прямого поширення, яка, за твердженням авторів, забезпечила оптимальний баланс між складністю моделі та її прогностичною здатністю. Для оцінки ефективності моделей використовувався коефіцієнт детермінації (R^2), також проводився аналіз портфеля для оцінки статистичної значущості отриманих прогнозів. Результати дослідження показали, що фінансові індикатори з усіх 10 категорій мають прогностичну силу щодо доходності акцій на китайському ринку. При цьому нелінійні моделі машинного навчання, зокрема нейронна мережа та випадковий ліс, продемонстрували кращі результати порівняно з лінійними моделями. Особливо важливими для прогнозування доходності акцій виявилися індикатори прибутковості та зростання. Цікаво, що дивіденди готівкою та новими акціями були визначені як найважливіший окремий фінансовий індикатор. Автори також відзначили, що квартальні фінансові індикатори мають прогностичну силу навіть для

щомісячної доходності акцій, що розширює можливості їх практичного застосування. Дане дослідження демонструє ефективність застосування методів машинного навчання для аналізу фінансових даних, а отримані практичні результати надають важливу інформацію щодо найбільш важливих категорій фінансових показників при прийнятті інвестиційних рішень.

Фінансові мережі – це математичні моделі, які відображають взаємозв'язки між фондовими ринками різних країн. У дослідженні “Global stock market investment strategies based on financial network indicators using machine learning techniques” [87] розглядається застосування показників фінансових мереж для розробки глобальних стратегій інвестування на фондовому ринку з використанням методів машинного навчання. Автори зосередились на вивченні ефективності цих показників для прогнозування напрямку руху глобального фондового ринку та визначення відносної привабливості розвинених ринків і ринків, що розвиваються. Дослідження включає порівняння ефективності різних методів машинного навчання для цих завдань. Методологія дослідження базується на побудові фінансових мереж волатильності з використанням кореляції Пірсона та моделі векторної авторегресії (VAR). Для аналізу даних застосовуються методи машинного навчання, зокрема логістична регресія (LR), випадковий ліс (RF) та метод опорних векторів (SVM). Результати дослідження демонструють, що включення показників фінансових мереж покращує точність прогнозування напрямку руху ринку на 2-5%, особливо для середньострокових прогнозів. Серед методів машинного навчання, метод опорних векторів показав найкращі результати. Особливо ефективними показники фінансових мереж виявилися під час фінансової кризи 2008 року. Використання цих показників в окремих інвестиційних стратегіях покращило річну прибутковість на 1-3% порівняно з моделями без них.

У дослідженнях з оптимізації фінансових портфелів все частіше застосовуються методи машинного навчання, зокрема, глибоке навчання з

підкріпленням (Deep Reinforcement Learning, DRL) та графові нейронні мережі. Автори дослідження, присвяченого використанню глибокого навчання для розробки інвестиційних стратегій [88], пропонують нову модель GRL (GraphSAGE and DRL coupled model), яка поєднує алгоритм GraphSAGE для обробки графових даних та алгоритм Proximal Policy Optimization (PPO) для глибокого навчання з підкріпленням. Ключовими компонентами запропонованої моделі є статичний фінансовий граф, який представляє взаємозв'язки між акціями, ринковими та галузевими індексами, та екстрактор ознак на основі GraphSAGE. Для вибору найбільш інформативних ознак автори використовують метод SHAP (SHapley Additive exPlanations). Нейронна мережа для DRL базується на архітектурі актор-критик, де актор генерує розподіл ймовірностей для ваг портфеля, а критик оцінює очікувану винагороду. Результати дослідження демонструють, що модель GRL перевершує базові стратегії, такі як стратегія рівної ваги та індекс S&P 500, за кількома ключовими метриками, включаючи ROI, коефіцієнт Шарпа, коефіцієнт Сортіно, максимальну просадку та коефіцієнт Кальмара. Особливо важливо відзначити, що модель показує кращу довгострокову стабільність і прибутковість, а також здатність адаптуватися до змін ринкових умов.

У контексті прогнозування динаміки фондових ринків, варто розглянути дослідження, що зосередилося на оцінці ефективності різних алгоритмів машинного навчання для передбачення напрямку руху фондових індексів розвинених країн [89]. Автори проаналізували основні індекси країн G7, включаючи NYSE 100 (США), NIKKEI 225 (Японія), FTSE 100 (Великобританія), CAC 40 (Франція), DAX 30 (Німеччина), FTSE MIB (Італія) та TSX (Канада), використовуючи щоденні дані за період з 1 січня 2012 року по 31 грудня 2021 року. Методологія дослідження базується на застосуванні семи алгоритмів машинного навчання: дерев рішень, випадкового лісу, k-найближчих сусідів, наївного Баєса, логістичної регресії, методу опорних векторів і штучних нейронних мереж. Як вхідні дані використовувалися

різноманітні технічні індикатори, такі як Moving Average, Weighted Moving Average, Exponential Moving Average, MACD, CCI, RSI, Stochastic %K, Stochastic %D, William's %R та Momentum. Результати дослідження показали, що штучні нейронні мережі (ANNs) демонструють найвищу середню точність прогнозування – 83,43%. За ними слідує логістична регресія (82,56%) та метод опорних векторів (79,43%). Цікаво відзначити, що ефективність алгоритмів варіювалася залежно від конкретного індексу. Так, ANNs показали найкращі результати для індексів NYSE 100, FTSE 100, DAX 30 і FTSE MIB, тоді як логістична регресія виявилася найефективнішою для NIKKEI 225, CAC 40 і TSX. Важливо підкреслити, що три алгоритми - ANNs, логістична регресія та SVMs - змогли спрогнозувати напрямок руху всіх досліджуваних індексів з точністю понад 70%. Дослідження демонструє потенціал алгоритмів машинного навчання, особливо штучних нейронних мереж, у прогнозуванні динаміки фондових індексів розвинених країн.

У сучасних дослідженнях з управління інвестиційним портфелем все частіше застосовуються методи штучного інтелекту та машинного навчання. Особливу увагу привертає використання глибокого навчання з підкріпленням (Deep Reinforcement Learning, DRL) та дистиляції знань (Knowledge Distillation). Дистиляція знань у контексті машинного навчання представляє метод передачі знань від складної моделі (або ансамблю моделей) до простішої моделі. Ці підходи дозволяють створювати більш адаптивні та ефективні стратегії управління активами. У статті “Knowledge distillation for portfolio management using multi-agent reinforcement learning” [90] представлено підхід, що поєднує DRL і дистиляцію знань у структурі "вчитель-учень". Їхня система складається з двох ключових компонентів: "вчителя" - мультиагентної системи, що моделює поведінку різних типів інвесторів на ринку, та "учня" - агента DRL, який навчається оптимальної стратегії розподілу активів. Дослідники розробили спеціальну архітектуру RAMA (Role-Aware Multi-Agent), яка дозволяє реалістично моделювати

взаємодію різних типів інвесторів на ринку. Результати дослідження показали значне покращення ефективності управління портфелем порівняно з традиційними методами та іншими підходами на основі DRL. Запропонована модель продемонструвала вищу прибутковість (на 48.8% у 2019 році та 25.1% у 2021) порівняно з методами, що навчаються безпосередньо на історичних даних. Крім того, модель показала кращі показники співвідношення ризику та доходності (коефіцієнти Шарпа та Сортіно) порівняно з базовими методами, такими як UCRP (Uniform Constant Rebalanced Portfolio), переможні стратегії (Winner), моделі на основі GAN (Generative Adversarial Networks), ARIMA (Auto-Regressive Integrated Moving Average) та MVMM (Multi-agent Virtual Market Model). Система показала стабільну ефективність на різних комбінаціях активів, що свідчить про її високу адаптивність та узагальнюючу здатність. Однак, варто зауважити, що модель також продемонструвала вищий показник Maximum Drawdown (MDD), що вказує на потенційно більший ризик значних втрат. Це підкреслює необхідність подальших досліджень для покращення балансу між прибутковістю та ризиком у подібних системах. Загалом дане дослідження демонструє перспективність застосування мультиагентних систем і дистиляції знань у поєднанні з DRL для створення більш ефективних стратегій управління інвестиційними портфелями.

У статті "Machine learning and the cross-section of emerging market stock returns" [91] досліджується застосування різних методів машинного навчання для прогнозування прибутковості акцій на ринках, що розвиваються. Автори порівнюють ефективність традиційних лінійних моделей, таких як звичайна лінійна регресія та еластична мережа, з більш складними нелінійними алгоритмами машинного навчання, включаючи випадковий ліс (RF), градієнтний бустинг регресійних дерев (GBRT) і нейронні мережі різної глибини. Дослідження базується на вибірці з 32 країн із ринками, що розвиваються, за період з 2002 по 2021 рік. Автори використовують 36 характеристик фірм для прогнозування майбутньої прибутковості акцій. Ці

характеристики включають фактори вартості, минулої прибутковості, інвестицій, поточної прибутковості, нематеріальних активів і торгових фрикцій. Для оцінки ефективності моделей застосовується методологія сортування портфелів, де акції розподіляються на квінтилі на основі прогнозованої прибутковості. Результати дослідження показують, що моделі машинного навчання, які враховують нелінійності та взаємодії між характеристиками, демонструють економічно та статистично кращі результати поза вибіркою порівняно з традиційними лінійними моделями. Зокрема, ансамбль нейронних мереж і комбінація методів машинного навчання (RF, GBRT і нейронні мережі) показали найкращі результати. Важливо відзначити, що перевага моделей машинного навчання зберігається навіть після врахування транзакційних витрат. Автори також виявили, що моделі, навчені виключно на даних розвинених ринків, здатні прогнозувати прибутковість акцій на ринках, що розвиваються. Це свідчить про наявність подібних взаємозв'язків між характеристиками компаній і майбутньою прибутковістю акцій на обох типах ринків.

У дослідженні [92] автори запропонували цікавий підхід до оптимізації розподілу інвестиційного портфеля акцій, який поєднує глибоке навчання з підкріпленням та аналіз настроїв ринку. Автори розробили модель, здатну автоматично приймати рішення про покупку або продаж акцій, враховуючи не лише історичні ціни, але й настрої ринку щодо компаній. Дослідження базувалося на портфелі з 30 компаній, включених до індексу Dow Jones Industrial Average, з використанням історичних даних за період 2001-2018 років. Методологія дослідження ґрунтувалася на адаптивному алгоритмі Deep Deterministic Policy Gradient (DDPG) з акторно-критичною архітектурою. Для аналізу настроїв ринку автори використовували інструмент VADER (Valence Aware Dictionary and sEntiment Reasoner), застосовуючи його до заголовків новин з Google News та дописів з мережі Twitter. Оцінки настроїв інтегрувалися в стан агента та впливали на функцію винагороди, що дозволило

моделі враховувати якісні фактори при прийнятті рішень. Результати дослідження продемонстрували значну перевагу запропонованого підходу над базовими методами. Модель, що враховує настрої ринку, досягла коефіцієнта Шарпа 2,07 порівняно з 1,49 у адаптивного DDPG, річної прибутковості 22,05% проти 18,84%, та меншого ризику з річним стандартним відхиленням 0,096 проти 0,116. З початкових інвестицій у \$10000 метод досяг кінцевої вартості портфеля \$25051, що значно перевищує результат адаптивного DDPG (\$21881). Ці показники свідчать про суттєве покращення здатності моделі балансувати між прибутковістю та ризиком завдяки врахуванню настроїв ринку. Дана робота підкреслює важливість інтеграції якісних факторів, таких як настрої ринку, в Robo-Advisor системи та автоматизовані системи торгівлі та ребалансування інвестиційного портфелю.

Окрім безпосереднього прогнозування дохідності чи оптимізації ваг активів, методи машинного навчання демонструють свою ефективність у вирішенні низки специфічних завдань інвестиційного процесу. Це включає покращення диверсифікації портфеля через кластеризацію активів, аналіз мультимодальних даних для виявлення складних ринкових закономірностей, а також інтеграцію якісних факторів, таких як ринкові настрої, у процеси прийняття інвестиційних рішень. У табл. 1.6 представлено огляд досліджень [22, 50, 92], що ілюструють нестандартні приклади застосування ML в автоматизованих системах фінансового консультування.

Таблиця 1.6

**Використання машинного навчання для вирішення
специфічних проблем в інвестиційному аналізі**

Задача / Проблема	Методологія / Ключові техніки	Ключові результати	Релевантність для RA систем
Оптимальний розподіл активів для непрофесійних інвесторів [22].	K-means кластеризація акцій (бета-фактор, об'єм торгів) для	Застосування кластеризації та методу жадібної оптимізації для підбору	ML методи, зокрема, кластеризація, можуть бути використані для

	диверсифікації + Теорія Марковіца (MPT) для оптимізації.	диверсифікованих портфелів знижує ризики без суттєвого зменшення прибутковості.	покращення процесу диверсифікації портфеля перед етапом оптимізації ваг активів.
Прогнозування різких падінь цін акцій з використанням мультимодальних даних [50].	Комбінація ринкових, графових (Node2vec) та текстових (аналіз настроїв) даних. Моделі: LightGBM, XGBoost, RF, LR.	Мультимодальний підхід значно перевершує моделі з одним типом даних. Графові дані мають високу значущість. LightGBM показав найкращу точність (75.85%).	Інтеграція різнорідних даних (ринкових, текстових, мережевих) за допомогою МН може суттєво покращити прогнозування екстремальних подій.
Оптимізація портфеля з урахуванням настроїв ринку [92].	Глибоке навчання з підкріпленням (DDPG) + Аналіз настроїв ринку (VADER для новин Google News і Twitter).	Модель, що враховує настрої, значно перевершила базовий DDPG (коефіцієнт Шарпа 2,07 проти 1,49, прибутковість 22,05% проти 18,84%).	Інтеграція якісних факторів (настрої ринку), отриманих за допомогою NLP/ML, в алгоритми навчання з підкріпленням дозволяє розробляти більш ефективні інвестиційні стратегії.

У дослідженні “Multiagent-based deep reinforcement learning framework for multi-asset adaptive trading and portfolio management” [93] запропоновано підхід до автоматизованої торгівлі на фондовому ринку та управління

портфелем активів, використовуючи методи глибокого навчання з підкріпленням (DRL). Автори розробили мультиагентну систему, яка поєднує різні аспекти аналізу фінансових даних: ціновий, технічний та аналіз патернів японських свічок. Ключовою особливістю їхнього підходу є використання алгоритму TD3 (Twin Delayed Deep Deterministic Policy Gradient), який є вдосконаленою версією DDPG (Deep Deterministic Policy Gradient). Запропонована система складається з двох основних модулів: Trading Action Module (TAM) та Trading Portfolio Module (TPM). TAM відповідає за генерацію торгових сигналів для кожного активу, інтегруючи аналіз цінових змін за допомогою LSTM та аналіз патернів свічок за допомогою CNN. TPM, у свою чергу, визначає оптимальні ваги для кожного активу в портфелі, використовуючи структуру ІІЕ (Identical Independent Evaluator) для незалежної оцінки активів. Цей модуль також враховує технічні індикатори та волатильність доходності для балансування ризику та доходності портфеля. Експериментальні результати, отримані на даних трьох акцій з Тайванської фондової біржі за період 2018-2022 років, показали, що запропонована система перевершує одноагентні алгоритми RL, досягаючи більш стабільних прибутків. Важливим аспектом дослідження є здатність системи ефективно розподіляти ваги активів у портфелі, зменшуючи ризики при негативних показниках. Автори також продемонстрували, що використання мультиагентної архітектури дозволяє досліджувати різні аспекти ринкового середовища та покращує навчання агентів. Крім того, запропонований підхід є масштабованим і може бути адаптований для роботи з різною кількістю активів, що є актуальним для універсальної Robo-Advisor системи.

У дослідженні “Multi-period portfolio optimization using a deep reinforcement learning hyper-heuristic approach” [94] розглядається ефективність застосування глибокого навчання з підкріпленням (DRL) у поєднанні з гіперевристичним підходом до задачі оптимізації інвестиційного портфелю. Автори пропонують підхід, який поєднує переваги DRL з гнучкістю

гіперевристики, що дозволяє системі адаптуватися до мінливих ринкових умов. Методологія дослідження базується на використанні алгоритму проксимальної оптимізації політики (PPO) для навчання агента DRL. Особливістю запропонованого підходу є те, що агент оперує не безпосередньо вагами активів у портфелі, а вибирає між різними торговими стратегіями, такими як Anticor, Buy and Hold та іншими. Це дозволяє значно звужити простір пошуку та підвищити ефективність навчання. Крім того, автори розширюють стан середовища, включаючи до нього технічні індикатори ринку (MACD, RSI, SO, FR), що надає агенту додаткову інформацію для прийняття рішень. Результати експериментів на п'яти реальних ринкових індексах (DAX, Hang Seng, FTSE, Nikkei, S&P) демонструють перевагу запропонованого методу над існуючими торговими стратегіями та базовими методами DRL. Зокрема, метод показав значно вищу річну прибутковість, покращивши результат другого найкращого методу на 65-296% залежно від ринку. Коефіцієнт Шарпа для запропонованого методу перевищив значення 2,0 на всіх п'яти ринках, що свідчить про високу ефективність з урахуванням ризику. Важливим результатом є також те, що отримані портфелі були краще диверсифіковані порівняно з базовими методами DRL, що підвищує їхню стійкість до ринкових ризиків.

Інвестиційні стратегії та алгоритми ребалансування інвестиційних портфелів мають враховувати не тільки фінансові показники тих чи інших інструментів, а й потейнційні наслідки глобальних кризових явищ. У дослідженні Наварро та ін. [95] розглядається проблема оптимізації портфеля акцій на фондовому ринку Філіппін в умовах пандемії COVID-19. Автори пропонують підхід, який поєднує технічний аналіз, алгоритм кластеризації K-means і модель оптимізації портфеля середньої дисперсії. Цей комплексний метод, названий TAKMV (Technical Analysis, K-means, Mean-Variance), спрямований на формування диверсифікованих портфелів з оптимальним співвідношенням ризику та доходності в умовах підвищеної волатильності

ринку. Результати дослідження демонструють, що ефективність різних технічних індикаторів змінюється залежно від ринкових умов. Зокрема, стратегія MACD (Moving Average Convergence/Divergence) показала кращі результати в період до пандемії COVID-19, тоді як гібридна стратегія MACD-ALMA (MACD з Arnaud Legoux Moving Average) виявилася ефективнішою під час пандемії. Автори відзначають, що MACD-ALMA краще працює в умовах високого ризику на ринку і може забезпечити максимальну очікувану дохідність портфеля. Запропонований метод TAKMV демонструє потенціал для покращення процесу прийняття інвестиційних рішень, особливо в періоди підвищеної ринкової невизначеності. Дослідження є важливим для розуміння динаміки фондового ринку під час глобальних криз та пропонує практичний інструментарій для оптимізації інвестиційних портфелів. Однак, як зазначають самі автори, подальші дослідження можуть бути спрямовані на застосування цього методу до інших фінансових ринків і вивчення його ефективності в постпандемічних умовах.

У дослідженні “Stock market prediction and portfolio composition using a hybrid approach combined with self-adaptive evolutionary algorithm” [96] представлено новий підхід до максимізації прибутку від інвестицій на фінансовому ринку, який поєднує еволюційні алгоритми (ЕА) з фундаментальними та технічними інвестиційними стратегіями. Автори розробили два типи ЕА: простий, з фіксованими параметрами, та самоадаптивний, де параметри операторів варіації включені в представлення рішень і еволюціонують разом із ними. Таке нововведення дозволило алгоритму автоматично налаштовувати свої параметри під час еволюції, що призвело до кращих результатів порівняно з простим ЕА у більшості випадків. Методологія дослідження включає використання F-Score для фундаментального аналізу та набір технічних індикаторів (RSI, EMA, MAC, ROC, MACD, VIX) для технічного аналізу. Автори експериментували з різними підходами до формування портфеля (статичний і динамічний) та

інвестиційними стратегіями (Buy-and-Hold і технічна торгівля). Для оцінки ефективності алгоритму було застосовано метод ковзного вікна з різними комбінаціями періодів навчання та тестування. Результати дослідження показали, що обидва підходи (технічний і фундаментальний) перевершили прибутковість індексу S&P500. Технічний підхід продемонстрував середню прибутковість 35,67% (найкраща – 57,34%), а фундаментальний - 39,49% (найкраща – 52,64%). Найефективнішою виявилася комбінація статичного портфеля та самоадаптивного ЕА. Цікаво, що технічний підхід краще працював на "ведмежому" ринку, уникаючи великих втрат, тоді як фундаментальний підхід показав кращі результати на "бичачому" ринку, досягаючи високих прибутків. Оптимальне ковзне вікно для обох підходів склало 2 роки навчання та 2 роки тестування. Загалом, дане дослідження демонструє потенціал комбінування еволюційних алгоритмів із методами фундаментального та технічного аналізу для оптимізації інвестиційних стратегій.

У дослідженні, присвяченому розробці моделі прогнозування руху волатильності фондового ринку з використанням методів штучного інтелекту [97], автори провели систематичний огляд літератури для виявлення найбільш ефективних індикаторів і моделей, після чого застосували дані індексу S&P 500 і 42 релевантних індикатори за період 1995-2023 рр. для побудови та оцінки 12 різних моделей, включаючи традиційні методи, алгоритми машинного навчання та глибокі нейронні мережі. Результати дослідження показали, що модель Light Gradient Boosting Machine (LGBM) продемонструвала найвищу точність – 98,2%, випередивши інші алгоритми за ключовими метриками ефективності, такими як F1-score (0,973) та ROC-AUC (0,983). Інші ансамблеві методи, зокрема XGBoost та AdaBoost, також показали високу ефективність з точністю 97,7% та 97,5% відповідно. Автори відзначають, що ансамблеві методи загалом перевершили інші алгоритми, що може бути пов'язано з їхньою здатністю ефективно обробляти складні

нелінійні залежності у фінансових даних. Аналіз важливості ознак, проведений за допомогою SHAP (SHapley Additive exPlanations) значень, виявив, що історичні цінові індикатори, особливо лагова дохідність, мають найбільший вплив на прогнози моделі. Індекс волатильності VIX також продемонстрував значний вплив, що підкреслює важливість врахування ринкових настроїв при прогнозуванні волатильності. Крім того, дослідження виявило суттєвий внесок технічних індикаторів, таких як RSI, Aroon, CCI, CLV та WPR, на точність прогнозів.

Висновки до розділу 1

На основі проведеного аналізу сучасних досліджень у галузі розробки систем фінансового консультування можна зробити висновок про те, що сучасні автоматизовані системи фінансового консультування (Robo-Advisor) набувають все більшої популярності завдяки своїм перевагам порівняно з традиційними фінансовими консультантами: доступність, низький поріг входу, можливість точного налаштування параметрів формування інвестиційного портфелю та можливість введення особистої накопичувальної системи пенсійного забезпечення. Особливої актуальності такі системи набувають в умовах високої інфляції, коли традиційні методи захисту заощаджень, такі як банківські депозити, не здатні компенсувати знецінення грошових заощаджень населення.

Крім того, аналіз сучасної наукової літератури демонструє стрімкий розвиток методів машинного навчання для прогнозування цін на фінансові інструменти. Особливу увагу дослідники приділяють використанню нейронних мереж архітектури LSTM, які показують найкращі результати при прогнозуванні часових рядів. Дослідження підтверджують ефективність використання як традиційних технічних індикаторів (MACD, RSI), так і

новітніх підходів із використанням аналізу настроїв ринку на основі обробки природньої мови.

Сучасні дослідження значну увагу приділяють розробці методів формування оптимального інвестиційного портфелю. Найбільш перспективними є підходи, що поєднують класичну теорію портфельних інвестицій Марковіца з методами машинного навчання для відбору найбільш перспективних активів. Дослідження підтверджують важливість диверсифікації портфелю як між різними класами активів, так і між різними галузями економіки.

В умовах високої волатильності фінансових ринків критичного значення набуває своєчасне ребалансування інвестиційного портфелю. Проаналізовані дослідження демонструють ефективність використання технічних індикаторів та сигналів підтримки/опору для визначення оптимальних моментів купівлі та продажу активів. Особливо перспективним є використання алгоритмів глибокого навчання з підкріпленням для автоматизації процесу ребалансування портфелю.

Проаналізовані дослідження також підтверджують важливість врахування психологічних факторів, індивідуальних особливостей і цілей інвестора при розробці систем автоматизованого фінансового консультування. Зокрема, важливо враховувати схильність недосвідчених інвесторів до необґрунтованих та емоційних рішень, які можуть призводити до значних фінансових втрат. Автоматизовані системи, що базуються на об'єктивних математичних моделях та алгоритмах, вочевидь, допомагають уникнути таких негативних ефектів.

Аналіз досліджень демонструє перспективність використання методів обробки природньої мови та великих мовних моделей для аналізу настроїв ринку та новин, що можуть впливати на динаміку цін фінансових інструментів. Поєднання такого аналізу з традиційними технічними та

фундаментальними показниками дозволяє підвищити точність прогнозування руху цін і покращити якість інвестиційних рішень.

Таким чином, проведений аналіз підтверджує актуальність подальших досліджень у напрямку розробки ефективних методів прогнозування цін на фінансові інструменти, формування оптимального інвестиційного портфелю та його автоматизованого ребалансування з використанням сучасних методів машинного навчання та технічного аналізу за допомогою автоматизованих систем фінансового консультування. Особливо важливим є створення комплексних рішень, що поєднують різні підходи та враховують як технічні, так і фундаментальні фактори при прийнятті інвестиційних рішень.

РОЗДІЛ 2.

МЕТОДОЛОГІЯ РОЗРОБКИ АВТОМАТИЗОВАНОЇ ІНФОРМАЦІЙНОЇ СИСТЕМИ ПЕРСОНАЛІЗОВАНОГО ФІНАНСОВОГО КОНСУЛЬТУВАННЯ

2.1 Архітектура автоматизованої системи фінансового консультування

Провівши аналіз основних функцій та алгоритму взаємодії користувача з системами для персоналізованих інвестиційних консультацій, було визначено основні логічні модулі типового Robo-Advisor сервісу. Підсумовуючи всі основні особливості АФК, про які йшлося в попередньому розділі, було розроблено високорівневу архітектуру RA, представлену на рис. 2.1. Дана архітектура передбачає, що RA є веб-сервісом, доступ до якого кінцевий користувач отримує через веб-браузер або мобільний додаток.

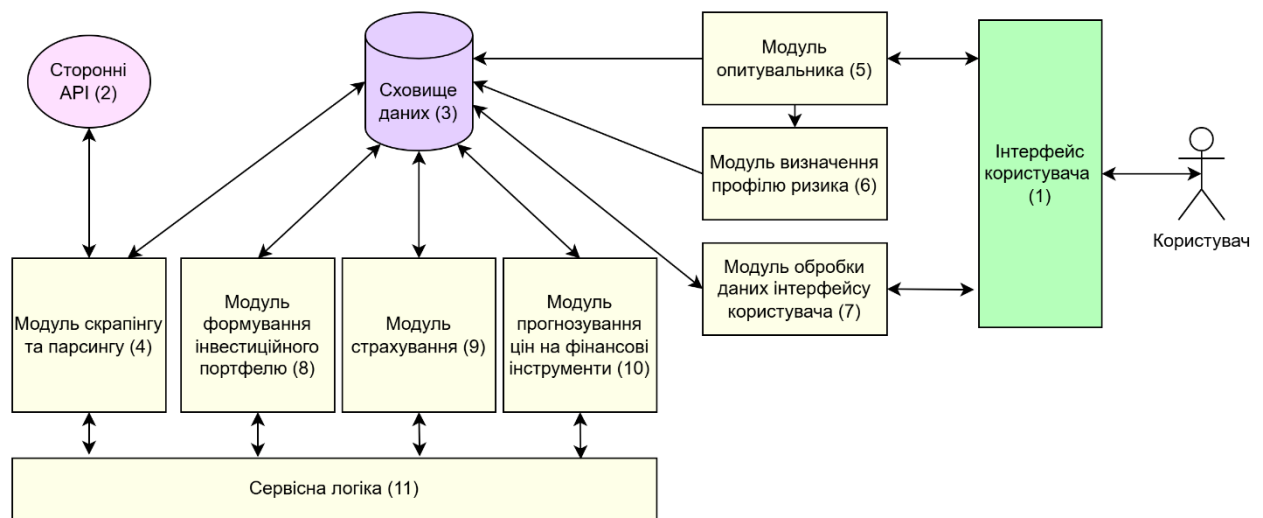


Рисунок 2.1. Високорівнева архітектура Robo-Advisor сервісу.

Передбачається, що процес взаємодії інвестора з Robo-Advisor системою включатиме наступні етапи:

- Опитування користувача. Визначення рівня доходу, ставлення до ризику, інвестиційних цілей та часових обмежень.

- Аналіз інформації, отриманої від користувача, для формування персоналізованого інвестиційного плану. На цьому етапі також буде використовуватись інформація про актуальні ціни на фінансові інструменти та історію їх змін в минулому.
- Представлення сформованого плану (інвестиційного портфеля) в інтерфейсі користувача з можливістю зміни певних параметрів (наприклад, користувач може виключити або додати певний тип активів) та оновлення (ребалансування) інвестиційного плану.
- Надання доступу до інформаційної панелі для відслідковування змін ключових характеристик інвестиційного портфелю.

Модуль, що забезпечує формування інвестиційного портфеля (8), є основною частиною системи. Він використовує дані, зібрані модулем парсингу (4) із зовнішніх джерел, та вхідну інформацію про очікуваний користувачем рівень дохідності, прийнятний рівень ризику тощо. Модуль страхування (9) - це частина програми, що відповідає за надання страхового плану на основі інформації, наданої користувачем. Його реалізація може відрізнятися залежно від національного законодавства. Модуль прогнозування прибутковості (10) використовує різні методи машинного навчання для побудови моделей, які можуть генерувати певні прогнози, наприклад, прибутковість акцій або середньоденний обсяг торгів. Сервісна логіка (11) - це модуль, який виконує фонові завдання, такі як періодичне ребалансування портфелів, оновлення моделей машинного навчання, а також виявляє аномальну поведінку цін на акції, щоб повідомити про це користувачів.

Модуль обробки даних інтерфейсу користувача (7) - це частина програми, відповідальна за обробку та відображення усіх даних, що відображаються в інтерфейсі користувача. Він може бути розділений на наступні логічні блоки:

- відслідковування зміни ціни активів, які цікавлять користувача;

- налаштування та відображення параметрів інвестиційного плану користувача (зміна рівня прийняттого ризику, рівня очікуваної прибутковості, встановлення періоду ребалансування);
- сповіщення в разі різкого падіння або зростання будь-якого активу, що використовується в портфелі користувача.

Під час роботи над практичною частиною даного дослідження замість веб-інтерфейсу користувача було розроблено чат-бот для месенджера Telegram, в якому реалізовано надання персональних інвестиційних консультацій для забезпечення сталого рівня споживання.

Модуль сховища (3) - це частина архітектури, відповідальна за організацію зберігання даних. Для кожного модуля необхідно використовувати тип сховища, який найкраще відповідає типу даних, з якими працює модуль. Для збереження даних про ціни на фінансові інструменти найкращим вибором буде спеціалізована база даних для часових рядів (InfluxDB, TimescaleDB, OpenTSDB). Для зберігання ML моделей підійде документна база даних або об'єктне сховище (MongoDB, Amazon S3). Для решти модулів передбачається використання реляційної бази даних (SQLite, MariaDB, PostgreSQL).

Кожен із модулів (4) - (11) може бути реалізований як окремий мікросервіс. Такий підхід допоможе масштабувати всю систему в майбутньому. Під час розробки даної архітектури передбачалося, що система буде реалізована з використанням наступних мов програмування, фреймворків і технологій:

- Back-end: Мова програмування Java, фреймворк Spring, реляційні та NoSQL бази даних, об'єктні сховища.
- Front-end: Мова програмування JavaScript, HTML та CSS для веб-клієнта; Flutter, React Native або інший крос-платформний фреймворк для мобільних додатків.

- Модуль прогнозування прибутковості: Мова програмування Python (з бібліотеками машинного навчання та аналізу даних, такими як NumPy, Scikit-learn, Pytorch, Pandas, TensorFlow).
- Інфраструктурний рівень: Docker, AWS для хмарних обчислень та реплікації сервісів, веб-сервер Nginx.

Незважаючи на те, що в багатьох роботах зазначається, що повністю автоматизовані процеси формування інвестиційного портфеля та відсутність будь-якої людської взаємодії є однією з відмінних рис РА [5, 9], багато клієнтів відзначають, що вони з певною недовірою ставляться до систем, які повністю позбавлені можливості живого спілкування з фінансовими консультантами [3]. Таким чином, система РА також повинна мати додатковий модуль, що забезпечує функціональність певного роду людських взаємодій між клієнтами та фінансовими експертами. Такі моделі взаємодії, що поєднують автоматизовані процеси з людською взаємодією, називаються біонічними моделями. Це може бути додаткова функція РА системи, яка не присутня в базовому плані, але може бути реалізована на вимогу користувача. Такий модуль не присутній у запропонованій архітектурі, але він доцільний для впровадження у подальших дослідженнях.

Застосування алгоритмів машинного навчання для прогнозування показників прибутковості та оптимізації інвестиційного портфеля, а також відповідна розробка серверної частини веб-додатка потребує вибору відповідних технічних рішень. Python - це мова програмування загального призначення з відкритим вихідним кодом. Згідно з індексом ТЮВЕ Programming Community, Python є найпопулярнішою мовою програмування [98]. Вона має багато сторонніх бібліотек, у тому числі призначених для машинного навчання та аналізу даних. Python підтримує всі найпопулярніші фреймворки машинного навчання, такі як TensorFlow, Keras, MXNet, Theano тощо [99]. Оскільки Python також підходить для бекенд-розробки веб-додатків, інтеграція модулів машинного навчання не викличе труднощів.

2.2 Моделі формування інвестиційних портфелів

Управління інвестиційним портфелем – це процес оптимального підбору різних активів у портфель на заздалегідь визначений період для досягнення визначеної інвестиційної цілі. Управління портфелем схоже на алгоритмічну торгівлю, за винятком часових рамок. Управління портфелем здійснюється протягом днів, місяців або років, тоді як алгоритмічна торгівля відбувається протягом від секунд до годин або днів. Сучасні методи управління портфелем розвиваються під впливом інноваційних DL-моделей та автоматизованих фінансових радників, які реалізують високопродуктивні автоматизовані системи підтримки прийняття рішень.

Найчастіше модуль АФК, що генерує інвестиційні портфелі, використовує модель Марковіца. Модель Марковіца – це математична модель формування портфеля активів таким чином, щоб очікувана дохідність була максимальною, а рівень ризику – мінімальним (2.1). Формальний запис цієї задачі має вигляд:

$$\begin{cases} R_p \rightarrow \max \\ \sigma_p \rightarrow \min \\ w_1 + w_2 + \dots + w_N = 1 \\ w_i \geq 0 \end{cases} \quad (2.1)$$

де N - кількість активів, R_p - очікувана дохідність, σ_p - рівень ризику (стандартне відхилення) і w_i – частка (відсоток) активу i у портфелі p . Загалом, таку задачу важко розв'язати, тому необхідно сформулювати первинну задачу Марковіца для інвестора, який хоче обмежити ризик (2.2) або обернену задачу Марковіца – для інвестора, який не бажає ризикувати (2.3):

$$\begin{cases} R_p \rightarrow \max \\ \sigma_p \leq \sigma_g \\ w_1 + w_2 + \dots + w_N = 1 \\ w_i \geq 0 \end{cases} \quad (2.2)$$

$$\begin{cases} R_p \geq R_g \\ \sigma_p \rightarrow \min \\ w_1 + w_2 + \dots + w_N = 1 \\ w_i \geq 0 \end{cases} \quad (2.3)$$

де σ_g - заданий рівень ризику та R_g - задана очікувана дохідність. Первинна задача використовується для формування портфеля таким чином, щоб очікувана дохідність була максимальною при заданому рівні ризику, тоді як обернена задача використовується для формування портфеля таким чином, щоб рівень ризику був мінімальним при заданому рівні очікуваної дохідності [10]. Водночас можна використовувати цільову функцію $\frac{\sigma_p}{R_p} \rightarrow \min$ для визначення інвестиційного плану нейтрального до ризику інвестора (2.4).

$$\begin{cases} \frac{\sigma_p}{R_p} \rightarrow \min \\ w_1 + w_2 + \dots + w_N = 1 \\ w_i \geq 0 \end{cases} \quad (2.4)$$

Таким чином, у будь-якому випадку задача Марковіца є прикладом оптимізаційної задачі, що розв'язується методами лінійного програмування.

Іншим способом є побудова інвестиційної стратегії за допомогою еволюційного алгоритму (ЕА). Дослідження, проведене В. Кобцем та М. Полторацьким [100], описує спосіб застосування еволюційного алгоритму для вибору оптимальної комбінації часток інвестицій у різних галузях для підвищення інвестиційної ефективності. З точки зору еволюційного програмування, популяція – це набір різних комбінацій розподілу між активами; генотип – це конкретний приклад розподілу активів; фенотип – це прибутковість певного розподілу активів; нащадки – це ті комбінації, які дають кращу прибутковість на кожній ітерації; функція пристосованості відповідає очікуваній прибутковості.

Під час роботи над практичною частиною дослідження було реалізовано програмний модуль, який генерує шаблони інвестиційних портфелів, базуючись виключно на анкетних даних про інвесторів. Дослідження

базується на загальнодоступному наборі даних від Objectway Financial Software [101]. Набір даних містить інформацію про 1172 анонімних банківських користувачів і портфелі, які вони обрали за допомогою професійних фінансових консультантів. Кожен портфель складається з фінансових інструментів, що відносяться до одного з 20 класів, наприклад, ETF, облігації, депозити тощо.

В експериментальній частині дослідження акцент зроблено на порівнянні п'ятих алгоритмів машинного навчання для задачі прогнозування частки кожного з 20 класів активів з урахуванням статі, віку, регіону проживання та профілю ризику інвестора. Спочатку було виконано прогнозування портфелів, використовуючи сервіс Simple ML for Sheets як бенчмарк. Результати, отримані бенчмарк-моделлю, будуть порівнюватися з результатами моделей LSTM, MLR, Regression Tree та Random Forest. Далі будуть коротко розглянуто вказані методи машинного навчання.

Simple ML for Sheets – це безкоштовне розширення для Google Sheets, яке пропонує автоматизацію багатьох етапів процесу машинного навчання, таких як вибір моделі, оптимізація гіперпараметрів і побудова самої моделі, щоб зробити машинне навчання більш доступним для широкого кола користувачів. Після завантаження файлу з набором даних необхідно вибрати тип завдання, яке хочемо вирішити (рис. 2.2). Це може бути передбачення відсутніх значень, виявлення аномальних значень або прогнозування майбутніх значень. Для складання інвестиційних портфелів було обрано варіант прогнозування відсутніх значень, для якого Simple ML пропонує три алгоритми на вибір: Gradient Boosted Trees, Random Forest та Decision Trees. Враховуючи, що нам потрібно передбачити вектор із 20 числових значень, найкращим вибором буде Gradient Boosted Trees.

Нейронна мережа з довготривалою короткочасною пам'яттю (LSTM) – це тип рекурентної нейронної мережі (RNN), яка має особливу архітектуру

прихованих шарів. LSTM-мережа може зберігати, забувати та змінювати свій внутрішній стан (пам'ять мережі), що дозволяє їй виявляти складні приховані залежності між вхідними даними під час навчання. Це робить LSTM-моделі досить ефективними в задачах із великими послідовностями і вирішує проблеми згасання і градієнтного вибуху. LSTM-мережа може ефективно обробляти й аналізувати довгі та складні послідовності, що робить її корисною в таких задачах, як обробка природної мови, прогнозування часових рядів та інших задачах, пов'язаних із послідовностями даних.

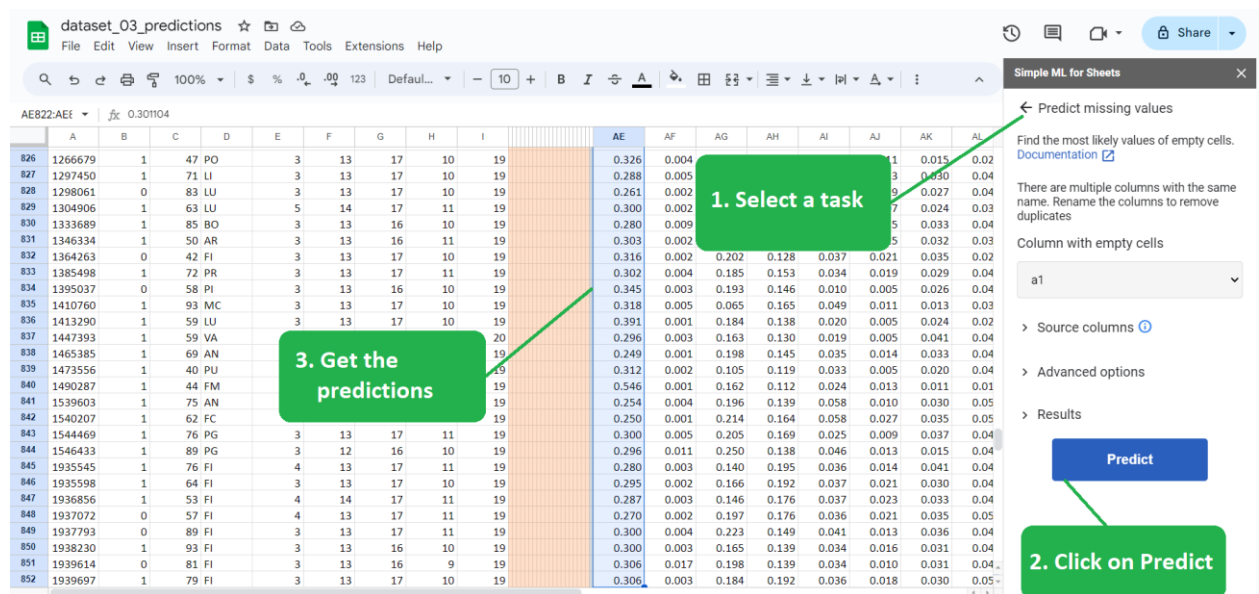


Рисунок 2.2. Інтерфейс Simple ML for sheets.

В одній із наукових публікацій, опублікованих в ході виконання даного дисертаційного дослідження, було доведено, що LSTM нейронна мережа показує прийнятні результати для прогнозування цін фінансових інструментів і може бути використана для формування інвестиційного портфелю з урахуванням не тільки історичних даних, а й прогнозів майбутніх цін [102]. Оскільки LSTM мережа буде використовуватися в модулі АФК для прогнозування цін на фінансові інструменти, було вирішено перевірити ефективність застосування цього методу машинного навчання і для задачі формування самого інвестиційного портфелю.

Під час експериментальної частини дослідження було використано архітектуру LSTM-моделі з одним прихованим шаром (неявний вхідний шар, LSTM-шар з 64-ма нейронами, які обробляють інформацію, вихідний шар з 20 одиницями). Для пошуку оптимальних значень гіперпараметрів (epochs та batch size) було реалізовано автоматичний підбір оптимальних гіперпараметрів за допомогою методу grid search.

Інші два методи машинного навчання, які було досліджено в експериментальній частині, - це дерево регресії та множинна лінійна регресія (MLR). Дерева регресії є різновидом дерев рішень, які спеціально розроблені для прогнозування числових значень. У той час як дерева класифікації (рішення) припускають категоріальні мітки, дерева регресії припускають числове значення для кожного вхідного екземпляра. Алгоритм дерева регресії рекурсивно розбиває набір даних на основі ознак для створення деревоподібної структури. Вузли дерева представляють прогнозовані числові значення для вхідних даних, які потрапляють у цей вузол. Дерева регресії доцільно використовувати, коли зв'язок між вхідними ознаками і цільовою змінною є нелінійним або коли вхідні дані складаються з різних типів даних. Дерева регресії, як і дерева рішень, добре інтерпретуються. Структуру дерева можна легко візуалізувати, що робить його придатним для пояснення прогнозів неспеціалістам. Для цього алгоритму також було реалізовано автоматичне налаштування гіперпараметрів (максимальна глибина, мінімальне розбиття вибірок та ін.) під час процесу навчання.

Множинна лінійна регресія (MLR) – це статистичний метод, який використовується для аналізу зв'язку між залежною змінною та двома або більше незалежними змінними (предикторами). Серед переваг MLR важливо виділити можливість оцінки статистичної значущості та інтерпретованості результатів. Методи множинної лінійної регресії надають статистичні показники, які можна використовувати для оцінки статистичної значущості кожної незалежної змінної.

Random Forest – це ML-алгоритм, який використовується для задач класифікації, регресії та інших завдань. Це різновид ансамблевого методу, який будує багато дерев рішень і комбінує їх для отримання більш надійного і точного прогнозу. Random Forest створює багато дерев рішень під час процесу навчання. Кожне дерево будується незалежно одне від одного, а процес побудови включає випадковий вибір підмножини даних і випадковий вибір підмножини ознак для побудови кожного дерева. Завдяки випадковому вибору даних та ознак, кожне дерево навчається на різних підмножинах, що допомагає зменшити ефект перенавчання та забезпечує високу точність прогнозу і хорошу здатність до узагальнення.

2.3 Методи прогнозування цін на фінансові інструменти та формування початкового інвестиційного портфелю з використанням методів машинного навчання

Сучасні фінансові ринки характеризуються високою динамікою та невизначеністю, що вимагає застосування передових методів прогнозування для формування оптимальних інвестиційних портфелів. Використання методів машинного навчання відкриває нові можливості для аналізу та прогнозування змін цін як традиційних фінансових інструментів, так і активів, що мають високий рівень волатильності. Останнім часом криптовалюта стала розглядатись як один із перспективних інвестиційних активів завдяки своїй потенційній прибутковості, проте її нестабільність вимагає постійного моніторингу та регулярного ребалансування портфеля.

Перерозподіл часток фінансових інструментів у портфелі відіграє ключову роль для максимізації очікуваного прибутку та мінімізації втрат, що особливо актуально для активів з високою волатильністю. На рис. 2.3 представлено динаміку зміни розподілу часток різних криптоактивів в інвестиційному портфелі, розрахованому на основі відкритих історичних

даних з сервісу Yahoo Finance з використанням моделі Марковіца для інвесторів, нейтральних до ризику [103]. Так, частка криптовалюти BCH у портфелі нейтрального до ризику інвестора змінилася з 0% (серпень 2017 року) до 100% (червень 2018 року).




Рисунок 2.3. Ребалансування інвестиційного портфеля для нейтральних до ризику інвесторів на основі відкритих даних сервісу Yahoo Finance
Джерело: авторські розрахунки [103].

Несвоєчасне ребалансування портфелю призводить до втрати доходу або збільшення збитків інвестора, тому виникає потреба у завчасному прогнозуванні курсів фінансових інструментів для мінімізації втрат інвестора, зокрема, з використанням методів машинного навчання.

Машинне навчання – це процес автоматизованого підбору параметрів, що використовується в спеціальних алгоритмах. Методи машинного навчання не мають детального наперед визначеного алгоритму для вирішення конкретної проблеми. Замість цього вони описують поступовий процес, за допомогою якого програма починає більш точно вирішувати задачу.

Сучасні методи машинного навчання активно використовуються в багатьох сферах людської діяльності. Найпоширеніші випадки використання - оптичне розпізнавання символів, класифікація та кластеризація, прогнозування часових рядів, тощо. Всі алгоритми машинного навчання

можна розділити на три основні категорії: з учителем, без учителя та навчання з підкріпленням. Табл. 2.1 містить коротке порівняння різних типів алгоритмів машинного навчання [104]. Використання будь-якого методу машинного навчання складається з трьох етапів: аналіз даних, побудова моделі, прогнозування на основі побудованої моделі [105].

Таблиця 2.1

Порівняння різних типів алгоритмів машинного навчання.

Тип	Опис	Приклади алгоритмів
Навчання з учителем	Класифікація	Визначення приналежності кожного елемента до однієї з відомих категорій на основі параметрів об'єкта.
	Регресія	Визначення взаємозв'язків між змінними та їхніх ваг.
	Прогнозування	Передбачення майбутнього на основі теперішніх даних.
Навчання без учителя	Кластеризація	Групування елементів у множини, де всі елементи схожі один на одного за визначеними критеріями.
	Зменшення розмірності	Зменшення кількості змінних без значної втрати даних.
Навчання з підкріпленням	Пошук найкращого рішення за допомогою покрокової оптимізації параметрів.	Глибоке навчання Рекурентні нейронні мережі

Джерело: підготовлено на основі [104].

Прогнозування проблем, пов'язаних із ризиками, можна здійснювати за допомогою як класичного машинного навчання, так і методів глибокого навчання, таких як випадковий ліс, згорткові нейронні мережі (CNN) і мережі з довготривалою короткочасною пам'яттю (LSTM). Хоча моделі глибокого навчання є хорошими системами прогнозування, необхідно підтвердити за

допомогою визначених критеріїв, чи в цій галузі вони дають кращий результат, ніж інші методи машинного навчання.

Далі буде наведено приклади використання двох методів машинного навчання з вчителем у Robo-Advisor системі. Формування початкового інвестиційного портфеля можливо виконувати, використовуючи не тільки вже відомі статистичні дані, але й прогнозовані значення (вартість, обсяг торгів тощо) активів. Під час роботи над практичною реалізацією програмного модуля для прогнозування прибутковості було використано та порівняно такі методи машинного навчання як множинна лінійна регресія (MLR) та модель рекурентної нейронної мережі з LSTM архітектурою.

Першим методом є лінійна регресія – класичний метод машинного навчання, який використовується для моделювання відповідності між деякою залежною змінною та однією або кількома пояснювальними (незалежними) змінними. Лінійна регресія також показує, які пояснювальні змінні мають більший вплив на значення залежної змінної. Вона може бути корисною у випадку, якщо у нас багато вхідних даних і ми хочемо зменшити їх кількість. Якщо є більше однієї пояснювальної змінної, модель називається множинною лінійною регресією. Формальний запис лінійної регресії виглядає наступним чином:

$$\gamma = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n + u = \beta_0 + \sum_{i=1}^n \beta_i x_i + u \quad (2.5)$$

де γ - залежна змінна, β_0 - константа, β_i - перетин (граничний вплив) для відповідної незалежної змінної ($i \geq 1$), x_i – незалежна змінна (предиктор), n - кількість факторів і u – похибка моделі.

Для того щоб побудувати MLR модель спочатку потрібно визначити критерії, які мають вплив на прогнозоване значення. Наприклад, у випадку прогнозування ціни акцій це може бути середньоденна ціна, обсяг торгів і

загальна пропозиція акцій за певний період часу. Модель лінійної регресії також допомагає зрозуміти фактори, що найбільше впливають на ціну.

Важливо зазначити, що при застосуванні лінійної регресії для прогнозування цін на фінансові інструменти необхідно враховувати певні особливості фінансових часових рядів. Зокрема, фінансові дані часто характеризуються нестационарністю, що може призвести до помилкових висновків при використанні класичної лінійної регресії. Для подолання цієї проблеми часто застосовують диференціювання часового ряду або використовують логарифмічні показники замість абсолютних значень цін.

При побудові регресійної моделі для фінансових ринків важливим етапом є відбір релевантних пояснювальних змінних. Окрім базових технічних індикаторів, таких як ковзні середні та показники волатильності, доцільно включати макроекономічні показники (наприклад, процентні ставки, індекси інфляції) та галузеві індикатори, що можуть впливати на динаміку цін конкретного фінансового інструменту. Також варто звернути увагу на показники настроїв ринку, такі як індекс волатильності VIX або індекси настроїв інвесторів.

Для оцінки якості побудованої моделі використовують різні метрики, найпоширенішими з яких є коефіцієнт детермінації (R^2), середньоквадратична помилка (RMSE) та середня абсолютна помилка (MAE). При цьому особливу увагу слід приділяти перевірці припущень лінійної регресії, зокрема, лінійності зв'язку між змінними, незалежності спостережень, відсутності мультиколінеарності, гомоскедастичності (постійної дисперсії помилок) та нормальності розподілу залишків. У випадку порушення цих припущень може виникнути необхідність у застосуванні більш складних модифікацій лінійної регресії, таких як узагальнена лінійна модель (GLM) або робастна регресія.

Практичне застосування лінійної регресії для прогнозування фінансових інструментів часто супроводжується використанням методів регуляризації,

таких як LASSO (Least Absolute Shrinkage and Selection Operator) або Ridge регресія. Ці методи допомагають запобігти перенаванчання моделі та покращити її прогностичні властивості, особливо у випадках, коли кількість пояснювальних змінних є значною. Крім того, вони автоматично виконують відбір найбільш значущих факторів, що спрощує інтерпретацію моделі та підвищує її практичну цінність для прийняття інвестиційних рішень.

Другий метод машинного навчання – це нейронна мережа з довготривалою короткочасною пам'яттю (LSTM) – ще один популярний алгоритм машинного навчання для прогнозування прибутковості активів. LSTM-нейронні мережі є підвидом рекурентних нейронних мереж (RNN). Основна відмінність LSTM мереж від звичайних нейронних мереж прямого поширення (FFNN) полягає в тому, що нейрони отримують інформацію не тільки з попереднього шару, але і з власного попереднього проходу. Таким чином, порядок, в якому ми надаємо дані і навчаємо мережу, має важливе значення. Однією з проблем в RNN архітектурі є проблема вибухового градієнта, яка призводить до швидкої втрати інформації з часом. LSTM нейронні мережі намагаються вирішити цю проблему.

Розглянемо спрощену архітектуру LSTM мережі (рис. 2.4). Жовті клітинки – це входні комірки, сині – комірки рекурентної пам'яті, а помаранчеві – вихідні. Кожен нейрон із прихованих шарів має спеціальну комірку пам'яті і фільтри, які вирішують, яка і скільки інформації буде зберігатися і передаватися на наступний шар. LSTM-мережі добре підходять для прогнозування часових рядів, оскільки вони можуть визначати і вивчати закономірності в поведінці досліджуваних даних, які повторюються через певні часові інтервали [106].

Архітектура LSTM містить кілька ключових компонентів, які забезпечують її ефективність при роботі з часовими рядами. Основними елементами є вентиль забування (forget gate), входний вентиль (input gate) та вихідний вентиль (output gate). Вентиль забування визначає, яку інформацію

слід видалити з клітинного стану. Він приймає рішення на основі попереднього прихованого стану та поточного входу, генеруючи число між 0 та 1 для кожного числа в клітинному стані. Значення, близьке до 1, означає "зберегти цю інформацію", тоді як значення, близьке до 0, означає "забути цю інформацію".




Рисунок 2.4. Схема нейронної мережі LSTM.

При застосуванні LSTM для прогнозування фінансових ринків особливу увагу слід приділяти підготовці вхідних даних. Важливим етапом є нормалізація даних, оскільки різні фінансові показники можуть мати різні масштаби та одиниці вимірювання. Популярними методами нормалізації є мінімаксна нормалізація та стандартизація (z-score нормалізація). Крім того, для покращення якості прогнозування часто використовується техніка ковзного вікна (sliding window), де модель навчається на послідовних часових відрізках фіксованої довжини.

Одним із ключових аспектів успішного застосування LSTM мереж є правильний підбір гіперпараметрів моделі. До основних гіперпараметрів належать: розмір прихованого шару (кількість LSTM-юнітів), кількість шарів, розмір батча (batch size), швидкість навчання (learning rate) та кількість епох навчання. Також важливим є вибір функції активації та оптимізатора. Для фінансових даних часто використовують оптимізатор Adam, який добре впорується з нестационарними даними та різними масштабами градієнтів.

Для боротьби з проблемою перенавчання у LSTM мережах застосовують різні методи регуляризації. Найпоширенішими є dropout (випадкове

"вимкнення" певної частки нейронів під час навчання) та L1/L2 регуляризація ваг. Також ефективним є метод раннього зупину (early stopping), який припиняє навчання, коли показники якості на валідаційному наборі даних перестають покращуватися. Це особливо важливо при роботі з фінансовими даними, де перенавчання може призвести до надмірної чутливості моделі до ринкового шуму.

При використанні LSTM для прогнозування фінансових інструментів важливо враховувати багатовимірність вхідних даних. Окрім історичних цін активу, модель може враховувати технічні індикатори (RSI, MACD, Bollinger Bands), обсяги торгів, ринкові настрої та макроекономічні показники. Для обробки такої багатовимірної інформації часто використовують багат шарові LSTM архітектури або комбінують LSTM з іншими типами шарів, наприклад, згортковими (CNN-LSTM архітектура).

Важливим аспектом є також інтерпретація результатів LSTM моделі. На відміну від класичних статистичних методів, нейронні мережі часто розглядаються як "чорні скриньки". Проте існують методи для аналізу важливості вхідних факторів, такі як аналіз чутливості (sensitivity analysis) або використання методу SHAP (SHapley Additive exPlanations). Це дозволяє краще зрозуміти, які фактори найбільше впливають на прогнози моделі, що особливо важливо для прийняття інвестиційних рішень.

2.4 Використання фінансових індикаторів та засобів алгоритмічної торгівлі для формування інвестиційної стратегії

Технічний аналіз є одним із ключових методів прогнозування цінових змін на фінансових ринках. Його основою є дослідження історичних даних, таких як ціни, обсяги торгів та інші ринкові індикатори. Головна мета технічного аналізу полягає у визначенні тенденцій, виявленні точок покупки і продажу активів, а також у прогнозуванні можливих змін вартості активів. Цей

підхід ґрунтується на трьох основних принципах. По-перше, вважається, що ринок враховує всі доступні дані. Це означає, що поточна ціна активу відображає всі економічні, політичні та навіть психологічні фактори. По-друге, ціни на ринку схильні рухатися у певних трендах: висхідних, низхідних або бічних. Тренди тривають, доки не з'являться суттєві причини для їх зміни. По-третє, історія на ринку повторюється, оскільки поведінка учасників часто базується на шаблонах і моделях, які спостерігалися у минулому.

У технічному аналізі використовуються різноманітні інструменти, які допомагають аналізувати ринок. Наприклад, графіки (лінійні, свічкові або стовпчикові) дозволяють візуалізувати зміну цін у часі. Фінансові індикатори, такі як ковзні середні, сприяють визначенню трендів та імпульсів. Технічний аналіз є популярним серед трейдерів завдяки своїй універсальності та об'єктивності. Він дозволяє швидко оцінити поточний стан ринку, ухвалюючи рішення на основі статистичних даних, а не лише інтуїтивного підходу.

Фінансові індикатори — це математичні розрахунки, що базуються на історичних даних, таких як ціни та обсяги торгів. Вони використовуються для аналізу ринкових тенденцій і прогнозування можливих змін на фінансових ринках. Трейдери, аналітики та інвестори застосовують ці індикатори для прийняття обґрунтованих рішень щодо купівлі, продажу або утримання активів. Серед найбільш популярних фінансових індикаторів виділяють:

- Ковзне середнє (Moving Average) — один із найпростіших і найзатребуваніших інструментів для аналізу ринкових трендів. Існує кілька типів ковзних середніх, зокрема просте (SMA) і експоненціальне (EMA). Вони допомагають згладжувати цінові коливання і виявляти довгострокові тенденції.
- Індекс відносної сили (RSI, Relative Strength Index) — показує, наскільки актив є перекупленим або перепроданим, використовуючи шкалу від 0 до 100. RSI є корисним для виявлення потенційних точок розвороту тренду.

- Рівні підтримки та спротиву — горизонтальні лінії на графіку, які позначають області, де ціна зазвичай сповільнюється або змінює напрямок. Підтримка – це рівень, де ціна має тенденцію зростати, а спротив – де вона зазвичай падає.

Фінансові індикатори відіграють важливу роль у розробці алгоритмів для автоматичного ребалансування інвестиційного портфеля. Наприклад, ковзаючі середні можуть допомогти визначити оптимальні точки входу і виходу з ринку. RSI може бути використаний для оцінки перекупленості чи перепроданості активів, що дозволяє коригувати вагу окремих інструментів у портфелі. Рівні підтримки та спротиву допомагають запобігти надмірному ризику, визначаючи зони для встановлення stop-loss (правило, яке автоматично виконає продаж активу, якщо ціна досягає заздалегідь визначеного рівня).

Алгоритми, що базуються на фінансових індикаторах, дозволяють зменшити вплив людського фактору, знизити ризики та забезпечити динамічне управління портфелем. Це робить інвестиції більш адаптивними до змін ринкових умов.

Задля забезпечення оптимального ребалансування інвестиційного портфеля, необхідно зрозуміти логіку визначення кожного з обраних індикаторів та експериментально довести їх ефективність. У ході експериментального дослідження було порівняно прибутковість інвестиційних портфелів, які змінюватимуть частки розподілу фінансових інструментів відповідно до сигналів купівлі або продажу певного індикатора технічного аналізу, порівняно з простою стратегією "купуй і тримай". Було обрано три індикатори технічного аналізу: Moving Average Convergence/Divergence (MACD), Support and Resistance (S&R) та Relative Strength Index (RSI). Всі три індикатори базуються на цінових значеннях за певний період часу в минулому, але використовують різні алгоритми для розрахунку своїх числових значень.

Проста ковзна середня (SMA) – це набір числових значень, розрахованих як середнє арифметичне певної кількості попередніх цінових значень (періодів). Ми можемо використовувати різну кількість періодів для розрахунку поточного значення SMA, і кожна кількість періодів буде давати різні значення SMA. Коли значення SMA, засновані на різних періодах, сходяться – це називається конвергенцією, а коли значення розходяться – дивергенцією (Moving Average Convergence / Divergence). Періоди для розрахунку SMA поділяються на короткострокові та довгострокові. В практичній частині роботи було використано два значення SMA (за останні 5 та 12 днів) для розрахунку MACD сигналу на купівлю або продаж. Стратегія MACD дає сигнал на покупку, якщо значення 5-денної SMA більше значення 12-денної SMA, і сигнал на продаж в протилежному випадку. 5-денна SMA відображає короткострокову тенденцію руху ціни. Порівняння 5-денної SMA з 12-денною дозволяє отримати ранній сигнал про зміну цінового тренду. Формула для визначення SMA:

$$SMA_n = \frac{A_1 + A_2 + \dots + A_n}{n} \quad (2.6)$$

де n – кількість періодів для обрахунку значення SMA, A_i – вартість активу A в період i .

Індекс відносної сили (Relative Strength Index, RSI) – ще один популярний технічний індикатор, який використовується у фінансовому аналізі для вимірювання імпульсу руху ціни активу, розроблений Джей Уеллсом Уайлдером [107]. Значення RSI розраховується шляхом порівняння величини нещодавніх цінових прибутків активу з його нещодавніми ціновими втратами за певну кількість попередніх часових інтервалів і коливається в діапазоні від 0 до 100. Формальний запис для розрахунку сигналу RSI виглядає наступним чином:

$$RSI(t) = 100 - \frac{100}{1 + RS(t)} \quad (2.7)$$

де t – номер попереднього часового інтервалу, а відносна сила ($RS(t)$) визначається шляхом ділення середнього прибутку на середній збиток за певний період. Коли RSI певного фінансового інструменту досягає значення 70 і вище, існує висока ймовірність того, що ціна незабаром знизиться (тобто це є сигналом для продажу). Коли значення RSI становить 30 або менше, то очікується зростання ціни актива, це вважається сигналом до купівлі (рис. 2.5).




Рисунок 2.5. Сигнали індикатора RSI на графіку EUR/USD.

Джерело: власна розробка.

Іншим підходом до технічного аналізу, який часто використовується у торгівлі на фінансових ринках, є стратегія підтримки та опору (S&R). Ця стратегія полягає у визначенні ключових цінових рівнів, на яких цінова дія, ймовірно, розвернеться в протилежному напрямку. Ці рівні називаються рівнями підтримки (коли ціна не опускається нижче певного ключового рівня) і опору (коли ціна не піднімається вище ключового рівня). Рівні підтримки та опору можна визначити за допомогою різних інструментів технічного аналізу, таких як трендові лінії, екстремальні значення, ковзні середні та відновлення Фібоначчі. У практичній частині дослідження було використано сигнали S&R, засновані на визначенні імпульсних змін ціни після довгострокової консолідації.

Окрім засобів технічного аналізу та індикаторів, важливим елементом дослідження ринку є фундаментальний аналіз. Фундаментальний аналіз передбачає оцінювання внутрішньої вартості активів на основі економічних, фінансових та інших кількісних і якісних факторів. Наприклад, для акцій це може включати аналіз фінансових звітів компанії, галузевих тенденцій, економічних індикаторів і геополітичних подій. Головною метою фундаментального аналізу є визначення, чи є актив переоціненим або недооціненим на ринку.

Дані, отримані за допомогою фундаментального аналізу, також можливо автоматизувати для використання в автоматизованих системах фінансового консультування. Ці системи здатні інтегрувати фундаментальні метрики, такі як співвідношення ціни до прибутку (P/E), дивідендну дохідність або показники боргового навантаження, з технічними індикаторами, забезпечуючи багатовимірний підхід до управління інвестиціями. Така інтеграція дозволяє створювати більш точні моделі для оптимізації портфелів і підвищення ефективності інвестиційних рішень.

2.5 Використання месенджерів як платформи для взаємодії з системою автоматизованого фінансового консультування

На етапі прототипування Robo-Advisor сервісу було вирішено реалізувати частину користувацького інтерфейсу у форматі чат-бота для одного з популярних месенджерів (таких як Telegram, Facebook Messenger чи Viber). Такий підхід має низку суттєвих переваг порівняно з розробкою повноцінного веб-інтерфейсу на ранніх етапах. По-перше, це дозволяє значно скоротити час розробки завдяки використанню готових API месенджерів та відсутності необхідності проєктувати складні інтерфейси користувача. По-друге, формат чат-бота надає гнучкість у модифікації бізнес-логіки та сценаріїв взаємодії з користувачем, що особливо цінно на етапі, коли повний

функціонал системи ще формується та уточнюється. Крім того, месенджери надають зручний інструментарій для швидкого тестування різних підходів до комунікації з користувачем та збору зворотного зв'язку, що допомагає краще зрозуміти потреби цільової аудиторії на ранніх етапах розвитку продукту.

В одній із робіт [108], опублікованих в рамках роботи над дисертаційним дослідженням, було представлено високорівневу архітектуру для типового Robo-Advisor сервісу, в якій зазначено, що модуль, який відповідає за взаємодію з користувачем, має реалізовуватися у вигляді веб-застосунку або мобільного додатку. В ході подальшої роботи було прийнято рішення розробити чат-бот з невеликим, проте зрозумілим і корисним для потенційного користувача (інвестора) функціоналом. Такий бот може використовуватися для швидкого ознайомлення користувача з загальною інформацією про можливості RA сервісу та водночас надавати певний корисний функціонал.

Месенджер (англ. Instant messenger) – це тип програмного інструменту, який дозволяє користувачам спілкуватися в режимі реального часу. Месенджери можуть мати централізовану архітектуру, коли передача даних здійснюється через сервери сервісу за допомогою спеціального протоколу, або пірінгову архітектуру, коли дані передаються безпосередньо від одного клієнта до іншого і немає необхідності в серверній стороні. Перші програми для обміну миттєвими повідомленнями були створені наприкінці 1990-х років і були доступні лише на персональних комп'ютерах. Протягом наступних двох десятиліть з'являлося все більше і більше сервісів для обміну миттєвими повідомленнями, і переважна кількість користувачів почала використовувати месенджери зі своїх смартфонів.

За останні 10 років загальна кількість користувачів додатків для обміну миттєвими повідомленнями зросла з 1,6 млрд у 2011 році до 7,5 млрд у 2021 році, а кількість унікальних користувачів, які використовують хоча б один із месенджерів, становить 4,48 млрд [109]. Графік найпопулярніших мобільних

месенджерів, побудований на основі кількості щомісячних активних користувачів, представлений на рис. 2.6.

Статистика серед користувачів Android-смартфонів в Україні показує, що найпопулярнішими месенджерами є Viber (97%), Telegram (77%), Facebook Messenger (72%) та WhatsApp. За даними з відкритих джерел, найбільший річний приріст кількості активних користувачів у Telegram - 25%, у Facebook Messenger - 7,4%, а у Viber - лише 6,8% [110, 111]. Тому, розробляючи бота для конкретної платформи, є сенс спочатку розглянути Telegram.

Кожен зі згаданих вище месенджерів дозволяє створювати чат-боти для комерційних або особистих цілей. Боти – це спеціальні акаунти, які керуються програмним забезпеченням. Вони можуть отримувати текстові або медіа-повідомлення від клієнтів і надсилати їм відповіді. Три найпопулярніші месенджери в Україні (Viber, Telegram та Facebook Messenger) надають безкоштовні інтерфейси прикладного програмування (API) для розробки чат-ботів, тоді як WhatsApp вимагає проходження бізнес-верифікації для отримання доступу до WhatsApp REST API [112]. Основні функції, які можуть бути реалізовані за допомогою чат-ботів, включають інформування, комунікацію та часткову або повну реалізацію певних інженерних бізнес-процесів для приватних та організаційних цілей.




Рисунок 2.6. Найпопулярніші мобільні месенджери у світі.

Джерело: підготовлено на основі [109]

При використанні чат-ботів визначення сентименту висловлювання часто залежить від контексту та часу розмови, а також від контексту та часу

використання чат-ботів. Виявлено, що позитивні висловлювання класифікуються чат-ботами з високою точністю, але класифікація негативних висловлювань викликає більше сумнівів [113]. Це означає, що чат-боти відповідатимуть правильніше, якщо питання описувати як числові вхідні дані.

Споживачі регулярно приймають рішення, і деякі з них є відносно простими, але прийняття інвестиційних рішень викликає невпевненість і тривогу через свою ризикованість, складність і відсутність обізнаності в питанні інвестицій у більшості людей. Звернення за порадою до експерта є розумним рішенням для будь-якого рівня ризику, але більшість інвесторів не звертаються за порадою до професіоналів. Як альтернативу людським консультантам все частіше використовують технології чат-ботів для надання швидких та ефективних порад, які допомагають інвесторам у прийнятті рішень [114].

На основі вивчених робіт [115, 116, 117] можна виділити наступні шляхи використання ботів як частини інших сервісів:

- Боти можуть бути точкою входу для клієнта в роботу з певним сервісом. Бот має надавати загальну інформацію про послугу та реалізовувати певний функціонал, щоб зацікавити та заохотити потенційних клієнтів користуватися послугою.
- Використання бота як засобу односторонньої комунікації (агрегація та показ інформації з різних джерел, сповіщення користувачів, інформування про нові пропозиції та новини).
- Використання бота як засобу двосторонньої комунікації (інтерактивний гід, служба підтримки). Цей тип використання зараз популярний в онлайн-банкінгу.
- Бот як самостійний сервіс.

Існує два способи розробки чат-бота незалежно від обраної платформи. Перший - розробка окремого додатку для кожної платформи з використанням

її API та набору для розробки програмного забезпечення (SDK). Інший варіант - використання спеціальних сервісів (таких як Pipe, Appy Pie, SnatchBot тощо), які надають можливість реалізувати логіку бота за допомогою своїх інструментів, а потім опублікувати його одразу на декількох платформах (Chatbot as a Service). Такі сервіси дозволяють створити мінімальний життєздатний продукт (MVP) або proof-of-concept (PoC) версію бота і швидко запустити його на різних платформах. Однак вони також мають і недоліки. Відмінності між цими підходами показані в табл. 2.2.

Таблиця 2.2

Порівняння різних підходів до створення чат-ботів.

Підхід	Переваги	Недоліки
Реалізація на замовлення	Можливість повною мірою скористатися всіма унікальними можливостями, які надає кожен із месенджерів. Мінімізація ризиків безпеки персональних даних користувачів.	Необхідність підтримки декількох версій одночасно. Нові функції та виправлення помилок слід впроваджувати для кожного бота окремо. Синхронізація даних.
Використання сторонніх сервісів	Швидке прототипування та створення MVP або PoC на різних платформах. Не потрібно підтримувати кілька версій кодової бази.	Значно обмежена функціональність у порівнянні з прямим використанням API. Підвищений ризик витоку персональних даних користувачів.

Джерело: підготовлено на основі [115, 116, 117].

Проаналізувавши деякі Telegram-боти, було виявлено наступні слабкі місця, які можуть негативно вплинути на досвід користувача і яких слід уникати під час розробки бота:

- У ботів із великою кількістю функцій складна, перевантажена і заплутана логіка роботи.

- Необхідно ретельно продумати і реалізувати логіку роботи бота на випадок некоректного введення даних користувачем.

Платформа Telegram використовує власну схему симетричного шифрування під назвою MTProto. Цей протокол шифрування базується на 256-бітному симетричному шифруванні AES, 2048-бітному шифруванні RSA і використовує метод обміну ключами Діффі-Хеллмана [118]. Telegram надає HTTP API, який охоплює всі функції, тому будь-який розробник може створити свій власний клієнт Telegram без необхідності працювати безпосередньо з протоколом MTProto. Telegram Bot API – це надбудова над Telegram API, яка надає можливість розробляти ботів. Існує безліч програмних бібліотек для різних мов програмування (включаючи PHP, JavaScript, Rust, Python, Java, Go тощо), які розробляються та підтримуються спільнотою з відкритим вихідним кодом [119].

Базові функції ботів включають отримання та надсилання текстових повідомлень і надання попередньо визначених швидких команд. Telegram Bot API також надає доступ до розширених функцій, таких як отримання та надсилання розширених повідомлень (стікерів, зображень, інших типів файлів) та створення власних екранних кнопок, що допомагає спростити та покращити користувацький інтерфейс [120]. У третьому розділі роботи буде розглянуто створення Telegram-бота для розрахунку необхідного рівня щорічних заощаджень для самостійного формування пенсійного забезпечення з використанням Telegram Bot API, мови програмування Java та фреймворку Spring Boot.

Розроблений Telegram-бот має використовувати математичну модель сталого рівня споживання для визначення суми, яку інвестор повинен щорічно вкладати в заощадження під реальний відсоток, щоб забезпечити постійний рівень споживання протягом встановленого періоду часу. Алгоритм взаємодії користувача з ботом складається з трьох основних частин: збір даних за

допомогою опитувальника, обробка даних користувачів за допомогою математичного апарату, представлення результатів користувачу.

Вхідні дані повинні містити інформацію про річний дохід людини (Y), вік, коли людина почне робити заощадження (t_1), вік, коли людина закінчить робити заощадження (t_2), вік, до якого людина планує витратити заощадження (t_3), очікувану номінальну річну відсоткову ставку за заощадженнями (r), а також інформацію про те, який відсоток зниження від очікуваної середньої відсоткової ставки буде критичним при прийнятті рішення про перегляд (припинення) програми заощаджень.

Перший крок - розрахунок майбутньої вартості ануїтету (2.8):

$$FVA = S \cdot \frac{(1 + rr)^{N_1} - 1}{rr} \quad (2.8)$$

де $N_1 = t_2 - t_1$, rr - реальна процентна ставка, яку можна знайти за допомогою рівняння Фішера (2.9):

$$rr = \frac{1 + r}{1 + i} - 1 \quad (2.9)$$

де r - номінальна відсоткова ставка та i - очікуваний рівень інфляції. Очікуваний рівень інфляції можна взяти з офіційної статистики за попередні 3 роки (2.10):

$$i = \sqrt[3]{i_1 \cdot i_2 \cdot i_3} \quad (2.10)$$

Під час реалізації бота було використано середній рівень інфляції в Україні за 2018, 2019 та 2020 роки з сайту ukrstat.gov.ua, який дає очікуваний рівень інфляції на рівні 1,063.

Наступний крок - визначення поточної вартості ануїтету (2.11):

$$PVA = C \cdot \frac{1 - (1 + rr)^{-N_2}}{rr} \quad (2.11)$$

де $N_2 = t_3 - t_2$. Для забезпечення постійного рівня споживання необхідно виконання наступного рівняння (2.12).

$$FVA = PVA \quad (2.12)$$

Дохід людини Y розподіляється між споживанням C та заощадженням S : $Y = C + S$, тому ми можемо позначити S як $Y - C$. Після того, як всі рівняння розв'язано, ми можемо обчислити обсяг споживання C і заощаджень S .

Висновки до розділу 2

У другому розділі дисертаційної роботи було розроблено та детально описано архітектуру автоматизованої системи фінансового консультування. Реалізація системи передбачається у вигляді веб-сервісу та включає наступні модулі: модуль взаємодії з користувачем, модулі для прогнозування цін на фінансові інструменти та формування і ребалансування інвестиційного портфеля, а також модулі сервісної логіки та обробки даних. Запропонована архітектура базується на сучасних технологіях, включаючи мови програмування Java та Python, і використовує підхід на основі мікросервісів, що забезпечує необхідну гнучкість та можливості для масштабування системи.

Також було розглянуто основні функції та вимоги до Robo-Advisor систем, систематизовано методологічні підходи до розробки автоматизованої інформаційної системи персоналізованого фінансового консультування, було сформовано цілісне бачення теоретичних і практичних аспектів створення такої системи.

В рамках дослідження теоретичних засад формування інвестиційних портфелів було проаналізовано класичну модель Марковіца. Ця модель дозволяє формувати оптимальні портфелі активів шляхом максимізації очікуваної дохідності при заданому рівні ризику або мінімізації ризику при заданій очікуваній дохідності. Такий підхід надає математично обґрунтовану основу для прийняття інвестиційних рішень з урахуванням індивідуальних

вподобань інвесторів щодо співвідношення ризику та очікуваної дохідності. Для підвищення очікуваної дохідності інвестиційних портфелів пропонується використовувати не лише наявні історичні дані про зміну цін на фінансові інструменти, а й прогнозовані ціни, отримані завдяки методам машинного навчання.

Значну увагу було приділено розробці комплексного підходу до прогнозування цін на фінансові інструменти. Запропонований підхід базується на використанні методів машинного навчання, зокрема множинної лінійної регресії та LSTM нейронних мереж, для прогнозування майбутніх цін активів. Для формування торгових сигналів та автоматизації процесу ребалансування інвестиційного портфелю сформовано вимоги до алгоритму автоматичного ребалансування, що базується на використанні індикаторів MACD, RSI та S&R.

Також було описано модель забезпечення постійного рівня споживання. Дана модель враховує широкий спектр параметрів, включаючи річний дохід, рік початку та завершення заощаджень, очікувану тривалість пенсійного періоду та номінальну процентну ставку. В основі моделі лежить розрахунок майбутньої та поточної вартості анuitету з урахуванням реальної процентної ставки, що дозволяє визначити оптимальний розподіл доходу між споживанням і заощадженнями для забезпечення постійного рівня споживання упродовж усього періоду планування. Дана модель може бути використана для визначення довгострокових цілей інвестора.

Окремо було обгрунтовано доцільність використання месенджерів як платформи для взаємодії з системою автоматизованого фінансового консультування. Проведений аналіз показав високу популярність месенджерів серед українських користувачів, зокрема Viber (97%), Telegram (77%) та Facebook Messenger (72%). На основі порівняльного аналізу можливостей різних платформ і підходів до розробки чат-ботів було сформульовано

функціонал та алгоритм роботи Telegram-бота для надання персоналізованих фінансових консультацій.

Таким чином, у другому розділі було сформовано комплексну методологічну базу для розробки автоматизованої системи фінансового консультування, яка поєднує класичні підходи до формування інвестиційних портфелів, методи машинного навчання та прогнозування, а також сучасні канали взаємодії з користувачами через месенджери. Запропоновані підходи створюють теоретичне підґрунтя для практичної реалізації системи, яка зможе автоматично надавати персоналізовані інвестиційні консультації широкому колу користувачів.

РОЗДІЛ 3.

РОЗРОБКА ПРОГРАМНИХ МОДУЛІВ АВТОМАТИЗОВАНОГО ФІНАНСОВОГО КОНСУЛЬТАНТА ТА АНАЛІЗ ЕФЕКТИВНОСТІ ОБРАНИХ МЕТОДІВ МАШИННОГО НАВЧАННЯ

3.1 Розробка модулів прогнозування цін на фінансові інструменти та формування інвестиційного портфелю

Для вирішення завдань машинного навчання було використано платформу Anaconda Data Science Platform. Anaconda – це програмний дистрибутив мов програмування Python та R для наукових обчислень, включаючи інструменти для розробки, обробки даних та візуалізації. Він також має на меті спростити управління пакетами та розгортання на будь-якій операційній системі. Список бібліотек, які були використані під час розробки програмного коду експериментальної частини дослідження, наведено в табл. 3.1. Усі вихідні коди до практичної частини дослідження, що описується в даному розділі роботи, розміщено в репозиторії сервісу GitHub за посиланням: https://github.com/serhii1savchenko/phd_projects.

Таблиця 3.1

Бібліотеки машинного навчання та обробки даних.

Бібліотека	Опис
yfinance	Дозволяє завантажувати ринкові дані з сервісу Yahoo! Finance
pandas	Бібліотека для аналізу даних і роботи з числовими таблицями.
numpy	Бібліотека з великою колекцією високорівневих математичних функцій та інструментів для роботи з багатовимірними масивами і матрицями.
matplotlib	Бібліотека для статичних, анімованих та інтерактивних візуалізацій.
keras	Бібліотека глибокого навчання з відкритим вихідним кодом.

sklearn	Бібліотека машинного навчання з відкритим вихідним кодом.
pyfpot	Python бібліотека, яка реалізовує методи оптимізації портфеля.

Основне завдання, яке стояло під час роботи над модулем прогнозування цін на фінансові інструменти, полягало в експериментальному підтвердженні доцільності використання обраних методів машинного навчання. Для експерименту було сформульовано дві задачі, які можуть виникнути в модулі прогнозування прибутковості Robo-Advisor сервісу. Перша задача полягає в тому, щоб спрогнозувати ціну фінансового інструменту на наступний часовий інтервал на основі даних про його ціну в минулому. Друге завдання – спрогнозувати ціну закриття певного фінансового інструменту на основі ціни його відкриття та обсягу торгів за попередній день.

Було використано відкриті історичні дані, що доступні у сервісі Yahoo Finance [121]. Ці щоденні набори даних включають дату, ціну відкриття, максимальну ціну, мінімальну ціну, ціну закриття та обсяг торгів для обраного фінансового інструменту. Під час розробки використовувалося програмне забезпечення Anaconda, що є потужним інструментом для наукових обчислень, і бібліотеки Python з відкритим вихідним кодом, такі як Pandas, Keras (з використанням TensorFlow) та Scikit-learn. Кожен із експериментів проводився на даних за останні 2 роки на момент проведення дослідження (з 17 грудня 2019 року по 17 грудня 2021 року) для наступних фінансових інструментів: Bitcoin (BTC-USD), Ethereum (ETH-USD), валютні пари EUR/USD та GBP/USD, акції Apple Inc. (AAPL) та Visa Inc. (V).

Перший експеримент було проведено з нейронною мережею LSTM. Як вже згадувалось раніше, нейронні мережі LSTM добре можуть впоратися з прогнозуванням часових рядів. Алгоритм експериментальної частини:

- Завантаження та очистка даних (видалення рядків з пропущеними значеннями);

- Нормалізація даних до діапазону від 0 до 1;
- Поділ даних на навчальну та тестову частини;
- Формування навчального та тестового набору даних в масиви X та Y так, щоб $X[i]$ містив ціну за день t , а $Y[i]$ містив ціну за день $t+1$;
- Створення LSTM моделі, визначення параметрів `epochs` та `batch_size`;
- Навчання LSTM моделі з використанням навчальної вибірки;
- Формування прогнозів на тестовій вибірці;
- Оцінка результатів за середньоквадратичною похибкою (RMSE).

Результати експерименту представлено на рис. 3.1 та в табл. 3.2. Останній рядок в табл. 3.2 показує відношення RMSE до останньої відомої ціни в наборі даних. На рис. 3.1 показано фактичні ціни та прогнози (вісь Y), зроблені на навчальному та тестовому наборах даних для Bitcoin та Ethereum. Найкращий результат було отримано при прогнозуванні співвідношення валютних пар.

Таблиця 3.2

Результати експерименту з мережею LSTM.

	BTC/USD	ETH/USD	EUR/USD	GBP/USD	AAPL	VISA
RMSE (тестовий набір)	2055,64	424,06	0,004956	0,005855	3,17	3,84
Час (сек)	58,7	58,73	41,94	42,38	40,71	39,8
Остання відома ціна (\$)	47561,85	3951,25	1,1339	1,3321	179,28	215,29
RMSE ratio	4,322%	10,732%	0,437%	0,4395%	1,768%	1,784%

Наступним кроком є спроба спрогнозувати ціну певного фінансового інструменту за допомогою отриманих LSTM моделей. Спробуємо спрогнозувати курс BTC на наступні x днів. Для цього використаємо цикл `for` з наступною логікою: на кожній ітерації ми будемо використовувати два

останніх передбачених значення для прогнозування наступного значення. Приклад коду для реалізації цього алгоритму наведено в лістингу 3.1.




Рисунок 3.1. Прогнозування цін на Bitcoin та Ethereum.

Джерело: власна розробка

```
future = testPredict[(len(testPredict)-2):len(testPredict),:]
future = scaler.transform(future)
forecast_duration = 13;

for i in range(forecast_duration):
    futureX = future[(len(future)-2):(len(future)-1),:]
    futureY = [future[len(future)-1,0]]
    futureX = numpy.reshape(futureX, (futureX.shape[0], 1, futureX.shape[1]))
    futurePredict = model.predict(futureX)
    future = numpy.concatenate((future, futurePredict), axis=0)

future = future[2:,:]
print('Forecast for next', forecast_duration, 'days:', future.tolist())
future = scaler.inverse_transform(future)
print('Inverse scaled values:', future.tolist())
```

Лістинг 3.1. Алгоритм прогнозування цін.

Порівняння фактичної та прогнозованої ціни біткоїна за 13 днів (з 18 грудня 2021 року по 30 грудня 2021 року) показано на рис. 3.2.




Рисунок 3.2. Порівняння фактичної та прогнозованої ціни біткоїна.

Очевидно, що прогнозована ціна не корелює з реальною ціною, хоча на тестовому наборі прогнози були досить якісними (рис. 3.1). Така різниця в результатах пояснюється тим, що в тестовому наборі даних для кожного наступного дня використовувалися реальні значення ціни за два попередні дні, в той час як у прогнозованому наборі використовуються власні прогнозовані значення, тому похибка накопичується занадто швидко. Вочевидь, модель, яка показувала непогані результати для прогнозування одного невідомого значення, не підходить для прогнозування одразу кількох майбутніх значень. Для довгострокового прогнозування цін за допомогою LSTM мереж слід використовувати метод ковзного вікна (sliding window), де розмір вікна – це кількість послідовних значень в часовому раді, що використовуються для прогнозування наступного значення при навчанні моделі. Для цього дані для навчання необхідно представити у вигляді $\{P_t, [P_{t-n}, \dots, P_{t-1}]\}$, тобто кожному відомому значенню ціни має відповідати масив із n попередніх її значень (наприклад, за останній тиждень або місяць). Варто також розглянути методи прогнозування багатовимірних часових рядів за допомогою LSTM-мереж (які використовують кілька вхідних ознак, а не тільки ціну), подальше налаштування кількості прихованих шарів нейронів і епох навчання, а також реалізацію дострокової зупинки навчання за допомогою зворотного виклику.

Як видно з табл. 3.2, нейронна мережа LSTM, яка будує прогноз на основі двох останніх відомих денних цін, має досить високе середньоквадратичне відхилення (RMSE) для таких високо волатильних фінансових інструментів, як криптовалюти та акції. Було вирішено спробувати підвищити точність прогнозування цін для цих фінансових інструментів, використовуючи тижневі ковзні середні (WMA) ціни. Результати показують, що такий підхід дозволяє пришвидшити час розрахунку (табл. 3.3), але значення RMSE зменшилось лише для криптовалюти Ethereum (рис. 3.3). Такий результат можна пояснити тим, що інші фінансові інструменти більше

залежать від зовнішніх факторів, таких як новинні настрої, запуск нового продукту тощо.

Таблиця 3.3

Експеримент з мережею LSTM на основі WMA.

	BTC/USD	ETH/USD	AAPL/USD	VISA/USD
RMSE (тестовий набір)	4460,38	326,45	4,49	6,18
Час (сек)	8,91	8,8	8,59	8,86
Середня ціна минулого тижня	48326,58	3963,93	177,19	211,95
RMSE ratio	9,23%	8,24%	2,53%	2,92%

При цьому відношення RMSE до фактичної останньої ціни значно нижче у валютних пар, що напряду пов'язано з їх значно меншою волатильністю у порівнянні з акціями та криптовалютою.




Рисунок 3.3. Прогнозування цін Bitcoin та Ethereum (WMA).

У другому експерименті було перевірено можливість спрогнозувати ціну закриття, використовуючи ціну відкриття та обсяг торгів попереднього дня (TVR) як вхідні параметри. Дані про щоденний обсяг торгів для валютних пар відсутні, тому для них було використано ціну закриття попереднього дня. Результати експерименту представлені в табл. 3.4 і на рис. 3.4. Алгоритм прогнозування ціни закриття (використовуючи MLR модель):

- Завантаження та очистка даних (видалення рядків з пропущеними значеннями);
- Вибір пояснювальної ознаки;

- Поділ даних на навчальну та тестову частини;
- Створення та навчання LinearRegression моделі;
- Формування прогнозів на тестовому наборі даних;
- Оцінка результатів за середньоквадратичною похибкою (RMSE).

Таблиця 3.4

Результати експерименту з множинною лінійною регресією.

	BTC/USD	ETH/USD	EUR/USD	GBP/USD	AAPL	VISA
RMSE (тестовий набір)	1910.6	175.85	0.00025	0.00033	1.95	2.73
Час (сек)	0.054	0.052	0.051	0.053	0.051	0.052
TVP	47190.45	3842.82	1.1316	1.3285	172.26	214.37
RMSE ratio	4.05%	4.58%	0.022%	0.025%	1.13%	1.27%




Рисунок 3.4. Прогноз ціни закриття Bitcoin та Ethereum.

На основі отриманих результатів можна зробити висновок, що метод множинної лінійної регресії може доволі точно передбачити ціну закриття фінансового інструменту на основі ціни відкриття та обсягу торгів за попередній день. Такий інструмент може бути корисним для короткострокових торгових стратегій. Однією з переваг множинної лінійної регресії є те, що вона показує, які предиктори мають найбільший вплив на залежну змінну. Ця інформація може бути використана для вибору ознак для інших методів машинного навчання, наприклад, багатовимірних нейронних мереж LSTM.

3.2 Використання прогнозованих значень цін фінансових інструментів при побудові інвестиційного портфелю

В ході реалізації модулю формування інвестиційного портфелю було проведено порівняння прибутковості трьох портфелів. Для експерименту було обрано наступний набір акцій: AAPL, GOOG, MSFT, AMZN, INTC, AMD, NVDA, F, TSLA, JPM, MS, VOO. Набір включає акції компаній із різних секторів економіки, таких як високі технології, мікроелектроніка, машинобудування, банківський і фінансовий сектор. Дані про історичні ціни всіх перерахованих вище компаній можна знайти у відкритому доступі на сервісі Yahoo Finance. Ціни закриття включають всю інформацію після відкриття торгів активами, тому ціна закриття є більш релевантною, ніж ціни відкриття, максимальні та мінімальні ціни.

Перший портфель побудовано на основі історичних даних про ціни закриття різних фінансових інструментів за два роки. Ще два портфелі побудовані з використанням додаткових даних з прогнозованими цінами закриття на наступний місяць. Прогнози ціни закриття на наступний місяць були зроблені для кожного фінансового інструменту за допомогою нейронної мережі LSTM та методу лінійної регресії. Експериментальна частина дослідження складається з наступних етапів (рис. 3.5):

- Збір історичних даних з відкритих джерел.
- Початкова обробка даних. Видалення рядків з відсутніми значеннями та нормалізація даних.
- Генерація прогнозу ціни закриття наступного місяця для кожного фінансового інструменту, використовуючи нейронну мережу LSTM та лінійну регресію.
- Побудова оптимального інвестиційного портфеля на основі лише історичних даних. Формування двох інвестиційних портфелів на основі історичних даних і прогнозів на наступний місяць.
- Порівняння відносної ефективності отриманих трьох портфелів.

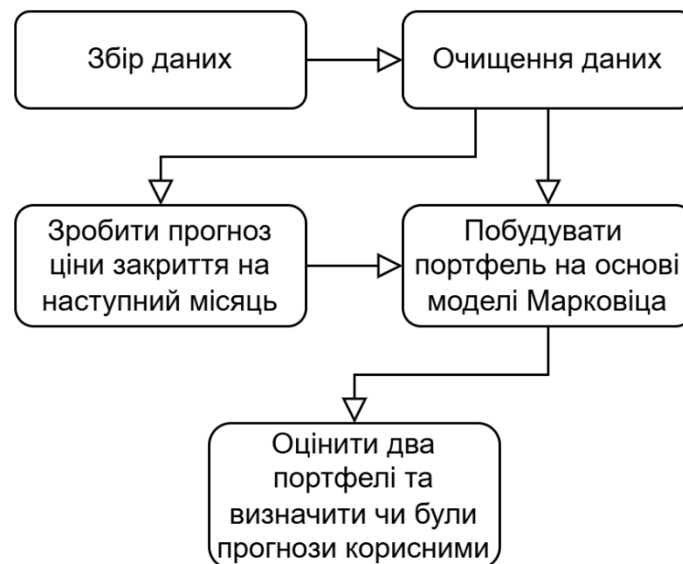


Рисунок 3.5. Діаграма робочого процесу експерименту.

Лістинги 3.2-3.5 відповідають першим чотирьом етапам робочого процесу. Було використано історичні дані про щомісячні ціни закриття дванадцяти акцій за десять років для навчання обох ML моделей. Після цього отримано прогноз ціни закриття наступного місяця для кожного тикера. Всі дані були отримані за допомогою бібліотеки `yfinance`, яка повертає значення у вигляді об'єкта `pandas dataframe` (лістинг 3.2).

```

tickers = ['AAPL', 'GOOG', 'MSFT', 'AMZN', 'INTC', 'AMD',
           'NVDA', 'F', 'TSLA', 'JPM', 'MS', 'VOO']

def get_month_data_from_yf(ticker, start_date, end_date):
    data = yf.download(ticker, start_date, end_date, interval='1mo', progress=False)
    return data.dropna()

data_ten_years = {}
for ticker in tickers:
    data_ten_years[ticker] = get_month_data_from_yf(ticker, '2012-01-01', '2022-01-01')
  
```

Лістинг 3.2. Завантаження даних з Yahoo Finance.

Після того, як всі дані завантажені, їх потрібно відфільтрувати від нульових значень і нормалізувати до значень у проміжку від 0 до 1. У наступному фрагменті коду відображена основна функція, яка приймає об'єкт датафрейму та назву тикера. Ця функція розділяє дані на навчальний і тестовий набори даних, створює LSTM-модель, навчається на навчальному

наборі даних і оцінює середньоквадратичну похибку (RMSE), а також повертає прогноз ціни закриття наступного місяця для заданого тикера. Набір даних було поділено на навчальну та тестову частини у співвідношенні 3 до 1.

```
def predict_nmcp(dataset, ticker):
    ...
    model = Sequential()
    model.add(LSTM(4, input_shape=(1, look_back)))
    model.add(Dense(1))
    model.compile(loss='mean_squared_error', optimizer='adam')
    model.fit(trainX, trainY, epochs=100, batch_size=1)
    ...
    prediction = model.predict(featureX)
    last_real_data_scaled = numpy.concatenate(
        (last_real_data_scaled, prediction), axis=0)
    next_month_inversed = scaler.inverse_transform(prediction)[0][0]
    return next_month_inversed
```

Лістинг 3.3. Основний метод прогнозування ціни закриття наступного місяця за допомогою LSTM.

Для визначення остаточного прогнозу використано середнє значення трьох незалежних прогнозів LSTM моделі (лістинг 3.4). Кожна ітерація має випадкові початкові ваги, модель навчається протягом 100 епох. Результат кожного прогнозу може відрізнитися через стохастичну природу алгоритмів, що використовуються в процесі навчання нейронної мережі.

```
def wcp_pred(data, ticker):
    prediction_1 = predict_nmcp(data, ticker)
    prediction_2 = predict_nmcp(data, ticker)
    prediction_3 = predict_nmcp(data, ticker)
    return (prediction_1 + prediction_2 + prediction_3) / 3

predictions = {}
for ticker in tickers:
    nmcp = wcp_pred(data_ten_years, ticker)
    predictions[ticker] = nmcp
    print(ticker, "PREDICTION =", nmcp)
```

Лістинг 3.4. Визначення остаточного прогнозу за трьома незалежними прогонами.

Було реалізовано окрему функцію для побудови прогнозу з використанням лінійної регресії. Тут немає потреби запускати процес навчання більше одного разу, оскільки цей алгоритм не має рандомізованих

параметрів. В якості пояснювальної змінної було визначено ціну закриття попереднього місяця. Вихідний код функції наведено в лістингу 3.5.

```
def mlr_predict_close_price(data, ticker):
    dataset = data[ticker] X = dataset[['Close-Previous-Month']].values
    y = dataset['Close'].values
    X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.33,
                                                         random_state = 0, shuffle = False)
    regressor = LinearRegression()
    regressor.fit(X_train, y_train)
    y_pred = regressor.predict(X_test)
    next_month_pred = regressor.predict([[y[len(y)-1]]])
    rmse = sqrt(mean_squared_error(y_test, y_pred))
    return [next_month_pred, rmse]
```

Лістинг 3.5. Прогнозування ціни закриття наступного місяця за допомогою лінійної регресії.

Лістинг 3.6 демонструє використання бібліотеки `rurfort`, що генерує оптимальний (з точки зору мінімальної волатильності) інвестиційний портфель на основі щомісячних даних про ціну закриття за два роки плюс одне значення з прогнозом ціни закриття наступного місяця, яке було згенероване за допомогою LSTM мережі або LR моделі.

```
data = yf.download(tickers, start='2020-01-01', end='2022-01-01', interval='1mo')
data = data['Close'].dropna()
d = datetime.datetime.strptime("01/01/2022", "%d/%m/%Y")
data_with_prediction = data.append(pandas.DataFrame(index=[d]))
for ticker in tickers:
    data_with_prediction.loc[d, ticker] = predictions_next_month_close_price[ticker]
mu = mean_historical_return(data_with_prediction, frequency=12)
S = CovarianceShrinkage(data_with_prediction,
                        frequency=12).ledoit_wolf()
ef = EfficientFrontier(mu, S, weight_bounds=(0,1))
weights = ef.min_volatility()
cleaned_weights = ef.clean_weights()
print(cleaned_weights)
ef.portfolio_performance(verbose=True)
```

Лістинг 3.6. Формування інвестиційного портфеля.

У табл. 3.5 наведено результати оцінки точності моделей LSTM та LR на тестовому наборі даних за середньоквадратичним відхиленням (RMSE). У четвертому та шостому стовпчиках наведено відношення оцінки RMSE до

значення останньої відомої ціни закриття. Найменші відхилення для LSTM прогнозів ціни закриття були отримані для тикерів VOO, GOOG та MSFT. Найменші відхилення для прогнозів LR також були отримані для тих самих тикерів.

У двох третирах випадків метод LR дав кращі результати прогнозування, однак різниця не дуже велика. Тому було складено інвестиційні портфелі з використанням як LSTM, так і LR прогнозів. Розподіл часток фінансових інструментів у портфелі, побудованому виключно на історичних даних (портфель 1), портфелі, де використовувався LSTM прогноз на наступний місяць (портфель 2), та портфелі, де використовувався LR прогноз (портфель 3), представлено в табл. 3.6. Всі портфелі побудовані для неохильних до ризику інвесторів. Це досягається шляхом введення умови мінімізації рівня допустимої волатильності (лістинг 3.6).

Таблиця 3.5

Результати прогнозування LSTM та LR.

Тикер	Ціна закриття (грудень 2021)	LSTM RMSE	Відсоток відхилення	LR RMSE	Відсоток відхилення
AAPL	177,57	10,3	5,8%	8,21	4,62%
GOOG	144,67	6,1	4,22%	6,18	4,27%
MSFT	336,32	14,4	4,28%	11,84	3,52%
AMZN	166,71	10,61	6,36%	11,29	6,77%
INTC	51,5	4,02	7,81%	4,16	8,08%
AMD	143,89	9,53	6,62%	9,97	6,93%
NVDA	294,1	19,63	6,67%	17,37	5,9%
F	20,77	1,23	5,92%	1,18	5,68%
TSLA	352,26	39,88	11,32%	30,07	8,53%
JPM	158,35	9,62	6,08%	8,95	5,65%
MS	98,16	5,63	5,74%	5,35	5,45%
VOO	436,57	16,7	3,83%	15,17	3,47%

На основі цих ваг було змодельовано динаміку зміни вартості кожного з портфелів протягом першого півріччя 2022 року (табл. 3.7). Початковий баланс кожного портфеля становить \$100000.

Таблиця 3.6

Розподіл часток фінансових інструментів.

Тикер	Портфель 1	Портфель 2	Портфель 3
AAPL	0	0	0
GOOG	0,05891	0,06402	0,05887
MSFT	0,17157	0,15357	0,1716
AMZN	0,14382	0,15413	0,14413
INTC	0,23247	0,25194	0,23252
AMD	0,00892	0,02014	0,00925
NVDA	0,09703	0,07661	0,09668
F	0,03027	0,02581	0,03003
TSLA	0	0	0
JPM	0,10737	0,1044	0,10767
MS	0	0	0
VOO	0,14964	0,14938	0,14926
Загальна сума	1	1	1

Таблиця 3.7

Динаміка зміни вартості кожного з портфелів.

Портфель	2022-01	2022-02	2022-03	2022-04	2022-05	2022-06
1	92412,17	90346,26	93524,80	79230,69	79893,63	70498,47
2	92440,91	90567,11	93587,40	79369,42	80160,87	70612,75
3	92412,64	90349,47	93528,66	79237,3	79900,72	70508,11

Таблиця 3.8

Порівняння очікуваної та реальної норми прибутку.

Портфель	Очікуваний прибуток за 6 місяців	Реальний прибуток за 6 місяців
1	+15,65%	-20,11%
2	+12,65%	-19,84%
3	+15,6%	-20,1%

За результати видно, що всі три портфелі втратили в ціні, але портфель, складений з урахуванням цінових прогнозів LSTM, демонструє кращу динаміку (менші втрати). Також цей портфель має найменшу різницю між очікуваним і реальним значенням 6-місячного доходу. На рис. 3.6 зображено

графік, що показує різницю у відсотках у втратах першого портфеля відносно другого.




Рисунок 3.6. Різниця у вартості двох портфелів (у відсотках).

Портфель 1 (побудований лише на історичних даних) має найбільшу різницю між очікуваним і реальним доходом. Наприклад, станом на лютий 2022 року портфель 1 втратив \$9653,74, а портфель 2 - \$9432,89. Таким чином, портфель, сформований з урахуванням прогнозу, отриманого за допомогою LSTM мережі, отримав збиток на 2,29% менший, ніж базовий портфель.

3.3 Використання машинного навчання для передбачення часток активів різних типів у початковому інвестиційному портфелі

Актуальність розв'язуваної проблеми та прогалина, яку заповнює дана частина дослідження, полягає у прогнозуванні розподілу часток різних класів активів в інвестиційному портфелі на основі профілів інвесторів і перевірці якості прогнозу за допомогою матриці помилок, що суттєво відрізняється від досліджень, в рамках яких прогножуються частки безпосередньо одного або кількох активів. На відміну від існуючих досліджень, в даному випадку прогножуються саме частки класів активів, а не їхні ціни, а досягнення інвестиційних цілей є компромісом між дохідністю та ризиком. Пропонування саме класів активів (наприклад, акції технологічних компаній США, криптовалюта або державні облігації) на першому етапі формування

інвестиційного портфелю є ефективним способом ознайомити користувача без попереднього досвіду в інвестиціях з тим, які фінансові інструменти йому доступні, в чому їх особливості та відмінності, які ризики притаманні тому чи іншому класу активів тощо.

Експеримент базується на наборі даних зі згадуваного в другому розділі дослідження [101]. Інформація про користувачів включає такі параметри: стать, вік, регіон проживання, ризик (числове значення від 1 до 5, менше значення означає більш несхильний до ризику тип інвестора), інвестиційні цілі, часові цілі, фінансовий досвід і фінансова доступність. Інформація про портфелі користувачів включає обсяг та ідентифікатор кожного активу, що входить до портфеля. Кожен актив складається з одного або декількох класів активів. Якщо актив складається з більш ніж одного класу активів, то вказується відсоток кожного класу активів. Загальна кількість унікальних активів становить 1002. Загальна кількість класів активів дорівнює 20, що значно менше, ніж загальна кількість всіх активів. При прогнозуванні часток активів у портфелі, розмір масиву, який ми будемо прогнозувати, дорівнює кількості усіх активів, тобто 1002. Враховуючи обмежену кількість параметрів, що описують самих користувачів, та задля того, щоб зменшити розмірність вихідного масиву, який необхідно спрогнозувати, було прийнято рішення трансформувати інвестиційний портфель з представлення у вигляді часток активів до представлення у вигляді часток класів цих активів. Процес трансформації даних зображено на рис. 3.7.




Рисунок 3.7. Процес перетворення даних.

Після проведення всіх перетворень набору даних ми отримаємо підготовлений набір даних у фінальному форматі (табл. 3.9). Значення в

стовпчику ac_i в табл. 3.9 відповідає частці активів класу i у відповідному портфелі, де $\sum_{i=1}^{20} ac_i = 1$.

Одним із основних параметрів, що визначає тип інвестора, а отже і класи активів, які він, найімовірніше, обере, є індивідуальна оцінка оптимального рівня ризику для інвестора. Якщо інвестор не схильний до ризику, інвестиційний портфель повинен відповідати умові мінімізації ризику, що призводить до вибору більш традиційних і захищених активів, таких як депозити, державні облігації, ETF тощо. Інвестор, який готовий до ризику, орієнтований на максимізацію очікуваної дохідності, тому включає в інвестиційний портфель більш волатильні фінансові інструменти.

Таблиця 3.9

Остаточний формат набору даних.

Ідентифікатор клієнта	Стать	Вік	Регіон	...	ac_1	...	ac_{20}
57829	Чоловік	53	PG	...	0.46	...	0
...
891172	Чоловік	67	AR	...	0.228	...	0.052

Джерело: дані підготовлено на основі [101].

Для оцінки типу ризикованості інвестора використовується методика діагностики ступеня готовності до ризику Шуберта [122]. Клієнт повинен заповнити анкету, що складається з 25 питань, на кожне з яких необхідно дати одну з відповідей: повністю згоден (2 бали), скоріше так (1 бал), не впевнений (0 балів), скоріше ні (-1 бал), повністю не згоден (-2 бали). Після цього слід порахувати суму балів, набраних клієнтом. Інтерпретація отриманих результатів (співвідношення кількості набраних балів зі ступенем ризикованості клієнта) представлено в табл. 3.10.

Таблиця 3.10

Готовність інвестора до ризику за тестом Шуберта [122].

Загальна кількість балів за тест	Результат тесту	Значення в наборі даних
< -30	Високий рівень обережності	1

[-30, -10)	Середній рівень обережності	2
[-10, 10]	Нейтральність до ризику	3
(10, 20]	Схильність до ризику	4
> 20	Висока схильність до ризику	5

Практична частина дослідження була виконана з використанням бібліотек (пакетів) з відкритим вихідним кодом для роботи з даними та для машинного навчання для мови програмування Python, в тому числі наступних:

- Pandas - бібліотека маніпулювання даними, що надає структури даних, які спрощують обробку та аналіз структурованих даних;
- NumPy - пакет для наукових обчислень на мові Python, що забезпечує підтримку великих багатовимірних масивів і матриць, а також математичні функції для роботи з масивами;
- Scikit-learn (sklearn) - бібліотека ML, яка надає прості та ефективні інструменти для аналізу та моделювання даних, включаючи різноманітні алгоритми класифікації, кластеризації та регресії;
- TensorFlow - фреймворк машинного навчання з відкритим вихідним кодом, який полегшує розробку та розгортання моделей глибокого навчання;
- Keras - бібліотека глибокого навчання, яка виступає високорівневим інтерфейсом для побудови нейронних мереж, що працюють поверх TensorFlow.

Процес попередньої підготовки даних для експериментів із різними алгоритмами машинного навчання однаковий і включає перевірку на відсутність нульових значень та нормалізацію всіх незалежних змінних у діапазоні значень [0...1]. Набір даних було поділено на навчальну та тестову частини у співвідношенні 70% на 30%. Загальний робочий процес проведення експериментів для всіх алгоритмів машинного навчання представлено на рис. 3.8.

Для оцінки ефективності кожного алгоритму було використано два показники – середньоквадратична помилка (RMSE) та точність за матрицею

помилки (confusion matrix, CM). Матриця помилок – це метод оцінки, який зазвичай використовується для оцінки ефективності алгоритму класифікації. Оскільки в експериментах ML-моделі використовуються для прогнозування розподілу часток різних класів активів у портфелі, були введені наступні правила для визначення істинних і хибних результатів передбачень:

- True Positive (TP): частка класу активів у прогнозі відрізняється від значення в реальному портфелі менше ніж на 10%;
- True Negative (TN): частка класу активів як у прогнозованому, так і в реальному портфелі дорівнює 0;
- False Positive (FP): частка класу активів у реальному портфелі дорівнює 0, а в прогнозованому - більше 0, або частка в прогнозі більша за частку в реальному портфелі більше ніж на 10% (хибнопозитивні);
- False Negative (FN): частка в прогнозі менша за частку в реальному портфелі більше ніж на 10% (хибнонегативні).




Рисунок 3.8. Загальний робочий процес експериментальної частини.

Після побудови матриці помилок можна обчислити точність та коефіцієнт помилок (3.1). Точність показує, яка частка всіх прогнозів була правильною, а коефіцієнт помилок показує частку помилкових прогнозів серед усіх прогнозів. Обидві ці метрики дають загальне уявлення про якість роботи моделі.

$$Accuracy = \frac{TP + TN}{Total}, \quad Error\ Rate = \frac{FP + FN}{Total} \quad (3.1)$$

В якості бенчмарк-моделі було використано результат передбачень, отриманих через Google Simple ML. Оскільки Google Simple ML не дозволяє вибрати кілька стовпців як цільові значення, було зроблено окремі прогнози для прогнозування кожної частки класу активів у портфелі (a1...a20). У

налаштуваннях Simple ML обрано тип завдання "Predict missing values" та алгоритм "Gradient Boosted Trees". Приклад результатів наведено на рис. 3.9.

sex	age	state	risk_profile	invest_goals	temp_goals	fin_exp	fin_avail	a1	a2	a3	a4	a5	a6	a7	a8	a9	a10	a11	a12	a13	a14	a15	a16	a17	a18	a19	a20	sum
1	69	GR	3	13	16	9	20	0.301	0.002	0.258	0.141	0.034	0.013	0.031	0.047	0.017	0.022	0.001	0.010	0.002	0.005	0.006	0.000	0.126	0.001	-0.001	0.001	1.018
1	46	PU	3	13	16	9	19	0.334	0.001	0.132	0.131	0.031	0.008	0.030	0.029	0.020	0.014	0.000	0.028	0.002	0.008	0.002	0.000	0.111	0.001	-0.002	0.001	0.883
1	73	PG	4	14	17	11	19	0.173	0.005	0.163	0.169	0.029	0.011	0.038	0.044	0.081	0.047	0.000	0.052	0.008	0.018	0.006	-0.001	0.086	0.003	0.016	0.001	0.951
1	36	AR	3	13	17	10	19	0.359	0.002	0.190	0.114	0.027	0.030	0.016	0.035	0.014	0.016	0.000	0.017	0.010	0.010	0.009	0.000	0.150	0.027	0.001	0.001	1.029
1	47	PO	3	13	17	10	19	0.326	0.004	0.189	0.165	0.031	0.011	0.015	0.028	0.046	0.018	0.000	0.015	0.001	0.022	0.002	0.000	0.124	0.001	0.014	0.001	1.014
1	71	LI	3	13	17	10	19	0.288	0.005	0.192	0.158	0.033	0.023	0.030	0.047	0.048	0.037	0.000	0.014	0.001	0.013	0.003	0.005	0.090	0.002	0.001	0.001	0.992
0	83	LU	3	13	17	10	19	0.261	0.002	0.194	0.148	0.028	0.019	0.027	0.041	0.021	0.021	0.000	0.013	0.003	0.012	0.008	0.000	0.135	0.004	0.001	0.001	0.939
1	63	LU	5	14	17	11	19	0.300	0.002	0.180	0.113	0.020	0.007	0.024	0.034	0.075	0.039	0.000	0.018	0.013	0.008	0.004	0.000	0.099	0.001	0.000	0.001	0.936
1	85	BO	3	13	16	10	19	0.280	0.009	0.227	0.207	0.033	0.015	0.033	0.043	0.025	0.015	0.000	0.007	0.001	0.013	0.003	0.000	0.130	0.001	0.005	0.001	1.049
1	50	AR	3	13	16	11	19	0.303	0.002	0.170	0.107	0.034	0.015	0.032	0.038	0.018	0.017	0.000	0.017	0.002	0.009	0.012	0.000	0.109	0.016	0.005	0.013	0.918
0	42	FI	3	13	17	10	19	0.316	0.002	0.202	0.128	0.037	0.021	0.035	0.025	0.014	0.016	0.000	0.011	0.002	0.009	0.003	0.000	0.100	0.002	0.000	0.004	0.927
1	72	PR	3	13	17	11	19	0.302	0.004	0.185	0.153	0.034	0.019	0.029	0.044	0.047	0.070	0.002	0.014	0.012	0.012	0.007	0.004	0.111	0.002	0.006	0.003	1.062
0	58	PI	3	13	16	10	19	0.345	0.003	0.193	0.146	0.010	0.005	0.026	0.046	0.036	0.031	0.000	0.037	0.002	0.011	0.030	0.002	0.100	0.001	0.001	0.001	1.025
1	93	MC	3	13	17	10	19	0.318	0.005	0.065	0.165	0.049	0.011	0.013	0.034	0.091	0.034	0.001	0.026	0.001	0.011	0.002	0.001	0.111	0.001	-0.007	0.004	0.951
1	59	LU	3	13	17	10	19	0.391	0.001	0.184	0.138	0.020	0.005	0.024	0.022	0.025	0.022	0.000	0.014	0.002	0.012	0.007	0.000	0.117	0.001	-0.001	0.001	0.984
1	59	VA	5	14	17	11	20	0.296	0.003	0.163	0.130	0.019	0.005	0.041	0.049	0.071	0.042	0.000	0.028	0.018	0.014	0.002	0.000	0.080	0.001	0.003	0.002	0.966
1	69	AN	3	13	16	11	19	0.249	0.001	0.198	0.145	0.035	0.014	0.033	0.048	0.031	0.057	0.000	0.028	0.001	0.011	0.002	0.001	0.159	0.001	0.000	0.001	1.015
1	40	PU	5	14	17	11	19	0.312	0.002	0.105	0.119	0.033	0.005	0.020	0.048	0.093	0.111	0.000	0.095	0.001	0.028	0.002	0.000	0.071	0.001	-0.001	0.001	1.044
1	44	FM	3	13	16	9	19	0.546	0.001	0.162	0.112	0.024	0.013	0.011	0.011	0.005	0.008	0.000	0.005	0.002	0.004	0.002	0.000	0.145	0.001	-0.002	0.001	1.053
1	75	AN	4	13	17	11	19	0.254	0.004	0.196	0.139	0.058	0.010	0.030	0.050	0.063	0.044	0.000	0.028	0.002	0.014	0.002	0.000	0.169	0.001	0.001	0.001	1.066
1	62	FC	3	13	17	10	19	0.250	0.001	0.214	0.164	0.058	0.027	0.035	0.050	0.023	0.013	0.000	0.014	0.001	0.022	0.005	0.000	0.124	0.001	0.002	0.003	1.008
1	76	PG	3	13	17	11	19	0.300	0.005	0.205	0.169	0.025	0.009	0.037	0.042	0.048	0.023	0.001	0.016	0.002	0.006	0.006	0.000	0.086	0.001	0.004	0.003	0.991
1	89	PG	3	12	16	10	19	0.296	0.011	0.250	0.138	0.046	0.013	0.015	0.044	0.036	0.017	0.001	0.013	0.002	0.005	0.012	0.004	0.164	0.001	0.000	0.001	1.068
1	76	FI	4	13	17	11	19	0.280	0.003	0.140	0.195	0.036	0.014	0.041	0.048	0.073	0.033	0.000	0.022	0.002	0.013	0.006	0.000	0.112	0.003	0.001	0.004	1.026
1	64	FI	3	13	17	10	19	0.295	0.002	0.166	0.192	0.037	0.021	0.030	0.049	0.036	0.018	0.000	0.014	0.001	0.011	0.011	0.000	0.096	0.002	0.001	0.002	0.985
1	53	FI	4	14	17	11	19	0.287	0.003	0.146	0.176	0.037	0.023	0.033	0.045	0.088	0.064	0.000	0.051	0.001	0.019	0.004	0.000	0.112	0.001	-0.002	0.009	1.097

Рисунок 3.9. Прогнози Google Simple ML.

Останній стовпчик містить суму прогнозованих часток класів активів у кожному портфелі, яка має дорівнювати 1. Оскільки фактична сума часток відрізняється від 1, а також іноді в прогнозах трапляються від'ємні значення, до всіх результатів були застосовані наступні модифікації:

- якщо значення менше 0,01, то воно дорівнює 0 (оскільки в реальних даних відсутні частки менше 1%);
- значення кожної частки ділиться на поточну суму всіх часток портфеля, в результаті сума всіх часток дорівнюватиме 1.

Основне завдання даного експерименту – визначити алгоритми машинного навчання, які показують найкращі результати з точки зору RMSE та найвищу точність. Результати, отримані за допомогою Google Simple ML (як повністю no-code підходу, що не потребує жодних навичок програмування та машинного навчання), також порівнювалися з іншими методами машинного навчання. У табл. 3.11 наведено оцінки RMSE для портфелів, складених за допомогою наступних моделей ML:

- Google Simple ML (GSML),
- Множинна лінійна регресія (MLR),

- Нейронна мережа LSTM з ручним налаштуванням гіперпараметрів (LSTM),
- Нейронна мережа LSTM з автоматизованим налаштуванням гіперпараметрів (LSTM_HP),
- Regression Tree з ручним налаштуванням гіперпараметрів (RT),
- Regression Tree з автоматичним налаштуванням гіперпараметрів (RT_HP),
- Random Forest з ручним налаштуванням гіперпараметрів (RF),
- Random Forest з автоматичним налаштуванням гіперпараметрів (RF_HP).

Для кожного алгоритму було проведено два експерименти з різним набором вхідних даних. Перший (повний) включає вісім ознак: стать, вік, регіон, профіль ризику, інвестиційні цілі, часові цілі, фінансовий досвід та фінансову доступність. Другий (короткий) включає лише стать, вік, регіон та профіль ризику.

Таблиця 3.11

Оцінка RMSE.

Алгоритм машинного навчання	Повний набір параметрів	Короткий набір параметрів
GSML	0,0666	0,0668
MLR	0,0652	0,0654
LSTM	0,0678	0,0678
LSTM_HP	0,0662	0,0663
RT	0,066	0,066
RT_HP	0,0654	0,0654
RF	0,0714	0,0737
RF_HP	0,0655	0,066

Як бачимо, для більшості алгоритмів значення RMSE є нижчим при використанні повного набору вхідних ознак, але різниця є досить незначною. Це свідчить про те, що ознаки статі, віку, регіону проживання та профілю ризику є більш важливими, а ознаки інвестиційних цілей, часових цілей,

фінансового досвіду та фінансової доступності є відносно неважливими при формуванні інвестиційного портфеля.

Моделі MLR, RT з автоматичним налаштуванням гіперпараметрів і RF з автоматичним налаштуванням гіперпараметрів дають найкращі результати з найменшим значенням RMSE. Оскільки повний набір вхідних ознак показав дещо кращі результати, подальші результати наведено для моделей, навчених на ньому. У табл. 3.12 наведено результати матриці помилок для всіх підходів. Візуалізація параметрів матриці помилок представлена на рис. 3.10.




Рисунок 3.10. Параметри матриці помилок.

Таблиця 3.12

**Результати матриці помилок
(навчання на повному наборі вхідних ознак).**

	GSML	MLR	LSTM	LSTM HP	RT	RT HP	RF	RF HP
TP	280	297	250	252	283	289	257	288
TN	2808	2907	2888	2785	2878	2840	2991	2849
FP	2334	2241	2290	2397	2277	2314	2172	2293
FN	1598	1575	1592	1586	1582	1577	1600	1590
True total	3088	3204	3138	3037	3161	3129	3248	3137
False total	3932	3816	3882	3983	3859	3891	3772	3883
Точність %	43,99	45,64	44,70	43,26	45,03	44,57	46,27	44,69

Помилки %	56,01	54,36	55,30	56,74	54,97	55,43	53,73	55,31
--------------	-------	-------	-------	-------	-------	-------	--------------	-------

Варто зауважити, що хоча модель Random Forest отримала найгірший показник RMSE, вона має найкращу точність серед інших алгоритмів.

3.4 Алгоритм автоматичного ребалансування для підвищення прибутковості інвестиційного портфелю

Технічний аналіз – це методологія, що виявляє певні закономірності та тенденції шляхом аналізу ринкових даних, таких як ціна та обсяг, і пропонує інвестиційні рішення. Технічний аналіз базується на припущенні, що історичні дані можуть бути використані для прогнозування майбутніх цінних значень. Інструменти технічного аналізу можна розділити на графічні інструменти (так звані графіки) та індикатори технічного аналізу [123]. Трейдери, які застосовують технічний аналіз, використовують графіки та технічні індикатори для інтерпретації ринкових даних та прийняття торгових рішень [124]. Під час розробки алгоритму автоматичного ребалансування інвестиційного портфелю увагу було зосереджено на трьох фінансових індикаторах: Moving Average Convergence/Divergence (MACD), Support and Resistance (S&R) та Relative Strength Index (RSI).

Початковою умовою розробленого алгоритму, який описано нижче, є попередньо сформований інвестиційний портфель. Раніше було описано метод формування початкового інвестиційного портфеля, який враховує бажання інвестора мінімізувати прийнятний ризик (3.2) або максимізувати очікувану дохідність (3.3). Це досягається за допомогою портфельної моделі Марковіца.

$$\begin{cases} R_p \geq R_g \\ \sigma_p \rightarrow \min \\ w_1 + w_2 + \dots + w_N = 1 \\ w_i \geq 0 \end{cases} \quad (3.2)$$

$$\begin{cases} R_p \rightarrow \max \\ \sigma_p \leq \sigma_g \\ w_1 + w_2 + \dots + w_N = 1 \\ w_i \geq 0 \end{cases} \quad (3.3)$$

Тут N - кількість активів, R_p - очікувана дохідність портфеля, σ_p - рівень ризику (стандартне відхилення), а w_i - відсоток активу i у портфелі p . Базовий інвестиційний портфель був побудований для нейтрального до ризику інвестора, коли відношення ризику до очікуваної дохідності мінімізовано (3.4), і включає дванадцять акцій.

$$\begin{cases} \frac{\sigma_p}{R_p} \rightarrow \min \\ w_1 + w_2 + \dots + w_N = 1 \\ w_i \geq 0 \end{cases} \quad (3.4)$$

Алгоритм використання індикаторів технічного аналізу для інвестиційного портфеля, що складається з декількох фінансових інструментів, представлений на рис. 3.11.

Першим кроком розробленого алгоритму є формування початкового інвестиційного портфеля на основі даних про минулі зміни цін на фінансові інструменти. Для цього використовується метод формування інвестиційного портфеля Марковіца. Якщо відправною точкою експерименту є, наприклад, січень 2021 року, то ми будемо використовувати дані за попередні п'ять років, тобто з січня 2016 року по грудень 2020 року. Після того, як початковий портфель сформовано, ми купуємо фінансові інструменти відповідно до їхньої частки в портфелі за ціною відкриття 2021 року.

В експериментальній частині порівнюються чотири портфелі. Перший відповідає стратегії Buy-and-hold. Це означає, що пропорція фінансових інструментів у його розподілі не змінюється. Інші три портфелі можуть бути перебалансовані, якщо від індикаторів MACD, RSI або S&R надходять сигнали на купівлю або продаж. Мета експерименту – дослідити динаміку зміни вартості кожного портфеля протягом одного року.

Алгоритм, що використовується для ребалансування портфелів, є універсальним для всіх трьох показників. Перевірка та ребалансування здійснюється наприкінці кожного тижня і складається з наступних кроків:

1. Перевірити, чи є в портфелі фінансові інструменти, для яких отримано сигнал на продаж і сигнал на купівлю. Сигнали на продаж враховуються тільки для тих фінансових інструментів, які не мають нульової частки в поточному портфелі. Якщо таких інструментів немає, ребалансування не виконується.
2. Серед фінансових інструментів, за якими надійшов сигнал на продаж (кандидати на продаж), вибрати один (тикер S):
 - а. Сформувати інвестиційний портфель на основі даних за останні п'ять років. Для кожного фінансового інструменту (з числа кандидатів на продаж) порівняти його частку в поточному портфелі з часткою в новосформованому портфелі. Якщо частка не змінилася або збільшилася, інструмент видаляється з кандидатів на продаж. Якщо частка зменшилася, потрібно розрахувати, яку частину фінансового інструменту слід продати. Для цього необхідно розрахувати, на скільки відсотків частка в новому портфелі менша за частку в поточному портфелі.
 - б. Якщо після зазначеної вище перевірки немає кандидатів на продаж, перебалансування не проводиться. Якщо є хоча б один кандидат на продаж, обирається той, що має найбільшу доходність від продажу відповідної частки.
3. Серед фінансових інструментів, за якими надійшов сигнал на покупку (кандидати на покупку), вибрати один (тикер В):
 - а. Для кожного кандидата на покупку розрахувати відсоток зміни вартості за останні п'ять років.
 - б. Вибрати фінансовий інструмент, вартість якого зросла найбільше або зменшилася найменше.

4. Якщо коштів, отриманих від продажу певної частки фінансового інструменту S , достатньо для придбання хоча б однієї цілої частки фінансового інструменту B , то здійснюємо процес продажу та купівлі відповідних фінансових інструментів за поточними цінами. Перераховуємо частки розподілу фінансових інструментів у поточному портфелі.
5. Якщо це не останній тиждень тестового набору даних, переходимо до кроку 1. В іншому випадку обчислюється остаточно вартість портфеля, використовуючи останні відомі ціни на фінансові інструменти з тестового набору даних.

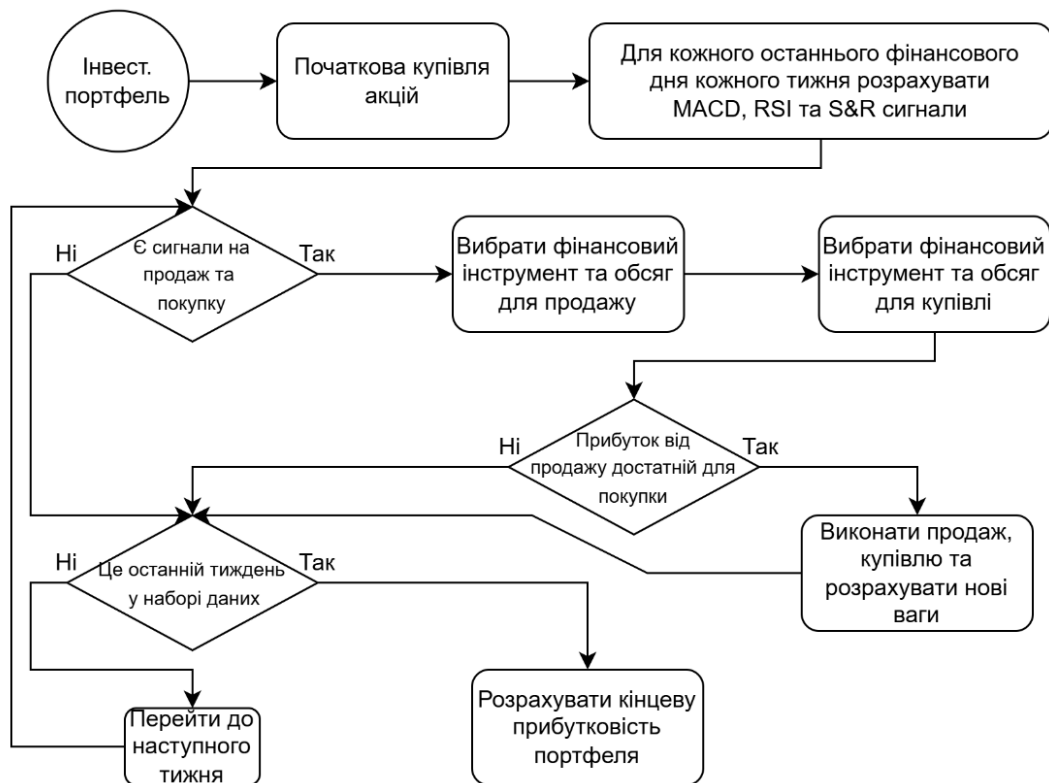


Рисунок 3.11. Схема роботи алгоритму ребалансування.

Оскільки ми знаємо всю історію змін пропорцій фінансових інструментів у портфелі та історію змін цін на кожен інструмент, то можемо розрахувати оціночну вартість портфеля в кожен момент часу, наприклад, на кінець кожного місяця. Також можемо розрахувати максимальну і мінімальну вартість портфеля з плином часу для подальшого порівняння портфелів, які

використовували різні стратегії ребалансування або які використовували стратегію "купуй і тримай".

Лістинги 3.7-3.9 демонструють основні частини реалізації запропонованого алгоритму. Для розробки експериментальної частини було використано мову програмування Python, платформу розробки Anaconda та бібліотеки з відкритим вихідним кодом numpy, pandas, matplotlib, rpyfort та yfinance.

Для експериментів у цьому дослідженні було обрано 12 акцій (AAPL, GOOG, MSFT, AMZN, INTC, AMD, NVDA, F, TSLA, JPM, MS, VOO). Цей набір включає акції компаній із різних секторів економіки, таких як високотехнологічні компанії (Apple Inc., Alphabet Inc., Microsoft Corporation, Amazon.com, Inc.), компанії з виготовлення мікроелектроніки (Intel Corporation, Advanced Micro Devices, Inc., NVIDIA Corporation), машинобудівні компанії (Ford Motor Company, Tesla, Inc.) та фінансові установи (JPMorgan Chase & Co, Morgan Stanley, Vanguard 500 Index Fund), що сприяє формуванню добре диверсифікованого інвестиційного портфеля.

Набір даних містить інформацію за п'ять років. П'ятирічний діапазон дозволяє врахувати середньо- та довгострокові тенденції зміни цін на фінансові інструменти. Історичні цінові дані для всіх компаній, що котируються на біржі, можна знайти на загальнодоступному сервісі Yahoo Finance [125].

Перший крок передбачає розрахунок початкового інвестиційного портфеля з використанням історичних даних про щоденні ціни закриття. Після того, як початковий портфель сформовано за класичною моделлю Марковіца за допомогою бібліотеки rpyfort, нам потрібно придбати акції відповідно до ваг, розрахованих у портфелі. Початковий баланс у прикладі становить \$100000.

Далі розраховуємо значення індикаторів MACD, RSI та S&R для кожного фінансового інструменту. Значення -1 відповідає сигналу на продаж, 1 - на купівлю, а 0 означає відсутність сигналу. Для індикатора RSI значення 70 або вище сприймається як сигнал до продажу, а значення 30 або нижче – як сигнал до покупки.

Також необхідно визначити допоміжні функції, які використовуються для вибору одного фінансового інструменту на продаж і одного фінансового інструменту на купівлю в разі надходження сигналу на продаж або купівлю для декількох фінансових інструментів одночасно.

Функція `check_tickers_for_sell` використовується для фільтрації акцій, за якими надійшов сигнал на продаж. Для цього розраховується інвестиційний портфель на основі актуальних історичних даних за останні п'ять років (той самий часовий проміжок, що використовувався для побудови початкового портфеля). Фінансовий інструмент позначається як кандидат на продаж, якщо частка цього фінансового інструменту в новому портфелі менша, ніж його частка в поточному портфелі. Частка, що підлягає продажу, розраховується як відсоток, на який частка в новому портфелі менша за частку в поточному портфелі (лістинг 3.7).

```
def check_tickers_for_sell(tickers_sell, now, current_weights):
    ticker_percent_sell = {}
    end_date = now.strftime('%Y-%m-%d')
    start_date = (now - relativedelta(years=5)).strftime('%Y-%m-%d')
    # Get data for all tickers for last 5 years
    data_for_tickers = yf.download(tickers, start_date, end_date, \
                                   progress=False)['Close'].dropna()

    # Generate portfolio on this data
    mu = mean_historical_return(data_for_tickers)
    S = CovarianceShrinkage(data_for_tickers).ledoit_wolf()
    ef = EfficientFrontier(mu, S, weight_bounds=(0,1))
    weights = ef.max_sharpe()
    new_weights = ef.clean_weights()
    # Filter tickers which have lower weight in new portfolio
    for ticker in tickers_sell:
        if new_weights[ticker] == 0:
            ticker_percent_sell[ticker] = 100
        elif new_weights[ticker] < current_weights[ticker]:
            delta = current_weights[ticker] - new_weights[ticker]
            sell_percent = (delta * 100) // current_weights[ticker]
            ticker_percent_sell[ticker] = sell_percent
    return ticker_percent_sell
```

Лістинг 3.7. Перевірка тикерів на продаж.

Серед інструментів, що пройшли перевірку, обирається той, який дасть найбільший прибуток від продажу відповідної частки (лістинг 3.8). Серед фінансових інструментів, для яких отримано сигнал на купівлю, обирається той, що має найбільший відсоток зростання ціни або найменший відсоток падіння ціни за останні 5 років (лістинг 3.9).

```
def select_ticker_for_sell(data, date, filtered_sell_tickers_with_percents, \
                          stocks_current):
    sell_ticker = ''
    sell_profit = 0
    stocks_to_sell = 0
    for ticker in filtered_sell_tickers_with_percents:
        no_of_stocks = stocks_current[ticker]
        cur_price = data[ticker][date]
        sell_percent = (filtered_sell_tickers_with_percents[ticker] / 100)
        potential_profit = no_of_stocks * cur_price * sell_percent
        if potential_profit > sell_profit:
            sell_profit = potential_profit
            sell_ticker = ticker
            stocks_to_sell = no_of_stocks * sell_percent
    return [sell_ticker, sell_profit, stocks_to_sell]
```

Лістинг 3.8. Вибір тикерів для продажу.

```
def select_ticker_for_buy(tickers_buy, now):
    if len(tickers_buy) == 1:
        return tickers_buy[0]
    end_date = now.strftime('%Y-%m-%d')
    start_date = (now - relativedelta(years=5)).strftime('%Y-%m-%d')
    data_for_tickers_last_year = yf.download(tickers_buy, \
        start_date, end_date, progress=False)['Close'].dropna()
    ticker_percent_delta = {}
    for t in tickers_buy:
        first_price = data_for_tickers_last_year[t][0]
        last_price = data_for_tickers_last_year[t]\
            [len(data_for_tickers_last_year[t]) - 1]
        delta = last_price - first_price
        delta_abs = abs(delta)
        percent = (delta_abs * 100) / first_price
        if delta > 0:
            ticker_percent_delta[t] = percent
        else:
            ticker_percent_delta[t] = -1 * percent
    sorted_by_delta = dict(sorted(ticker_percent_delta.items(), \
        key=lambda x:x[1], reverse=True))
    return list(sorted_by_delta.keys())[0]
```

Лістинг 3.9. Вибір тикера для купівлі.

Після завершення всіх операцій з ребалансування буде отримано остаточний варіант інвестиційного портфеля, який враховує всі зміни в розподілі часток фінансових інструментів. Порівняння результатів, отриманих за допомогою стратегій MACD, RSI та S&R відносно базової стратегії "купуй

і тримай", представлено далі. Порівняння включає чотири критерії: підсумкова вартість інвестиційного портфеля, максимальна вартість, мінімальна вартість і максимальна різниця між портфелем, в якому частки фінансових інструментів змінювалися відповідно до сигналів на купівлю або продаж, і портфелем без змін у розподілі часток фінансових інструментів.

У табл. 3.13 наведено порівняння динаміки зміни вартості чотирьох портфельів у 2021 році. У першому портфельі частки фінансових інструментів не змінювалися протягом усього періоду. В інших портфельях використовувалася стратегія щотижневого ребалансування відповідно до сигналів певного індикатора (MACD, RSI або S&R). Детальну розшифровку результатів роботи алгоритму ребалансування з використанням індикатора S&R на даних за 2021 рік представлено в додатку А.

Таблиця 3.13

Зміна вартості портфельів (2021 рік).

Дата	Buy&Hold	MACD	RSI	S&R
2021-01-29	100383,33	99617,89	100383,33	100383,33
2021-02-26	96859,97	95738,59	96859,97	96859,97
2021-03-31	94124,58	92538,74	94124,58	94251,82
2021-04-30	102026,81	99750,20	102026,81	102426,55
2021-05-28	100352,40	98422,86	100352,40	100698,61
2021-06-30	116128,21	111082,50	115941,38	117145,00
2021-07-30	119255,91	113388,36	119264,85	122469,00
2021-08-31	129365,25	121126,30	129096,94	131121,99
2021-09-30	123008,61	117461,52	123368,31	127097,62
2021-10-29	149742,30	149184,43	151142,82	158524,52
2021-11-30	179374,49	167608,01	171513,58	188390,81
2021-12-31	165761,09	156703,32	166938,95	175820,61

У табл. 3.14 показано мінімальну та максимальну вартість кожного портфеля, а також порівняно максимальну та кінцеву різницю у вартості портфеля відносно портфеля, в якому розподіл фінансових інструментів не змінився (портфель без ребалансування).

Таблиця 3.14

Порівняння стратегій ребалансування (2021 рік).

Стратегія	Підсумкове значення	Максимальне значення	Мінімальне значення	$\Delta \max$	Δfinal
MACD	156703,32	169608,5	84659,33	-7,6%	-5,46%
RSI	166938,95	173551,9	84853,55	-4,3%	+0,71%
S&R	175820,61	189987,09	84853,55	+7,4%	+6,06%
Buy&Hold	165761,09	181497,87	84853,55	-	-

За результатами експерименту стратегія на основі сигналів індикатора S&R показала найкращі результати. Кінцева вартість портфеля, який було ребалансовано на основі сигналів S&R, виявилася на \$10059,51 більшою, ніж вартість портфеля buy-and-hold. Кінцева вартість портфеля, для ребалансування якого використовувалися сигнали RSI, майже не відрізняється від вартості портфеля "купуй і тримай".

Найгірший результат показав портфель, що використовував для ребалансування сигнали MACD, його кінцева вартість на \$9057,77 менше, ніж у портфеля buy-and-hold. Порівняння динаміки зміни вартості портфельів buy-and-hold, S&R та інших портфельів показано на рис. 3.12.




Рисунок 3.12. Порівняння вартості портфельів протягом 2021 року.

Також було проведено експеримент з використанням даних за 2022 рік. У табл. 3.15 наведено порівняння динаміки вартості чотирьох портфелів протягом 2022 року (перший портфель не був ребалансований, у трьох інших використовувався певний індикатор для ініціювання ребалансування). У табл. 3.16 наведено мінімальну та максимальну вартість портфелів, а також порівняння максимальної та кінцевої різниці у вартості портфелів відносно портфеля, в якому розподіл часток фінансових інструментів не змінювався.

Таблиця 3.15.

Зміни вартості портфелів (2022 рік).

Дата	Buy&Hold	MACD	RSI	S&R
2022-01-31	90767,87	90663,28	90767,87	90796,80
2022-02-28	87297,44	86870,19	87297,44	87823,22
2022-03-31	94891,88	97009,02	94891,88	93663,53
2022-04-29	80058,02	81071,75	80058,02	77692,61
2022-05-31	76541,45	78762,79	76541,45	73925,83
2022-06-30	68428,17	68706,80	68428,17	68446,40
2022-07-29	82081,15	84984,39	82081,15	79422,51
2022-08-31	76470,10	77905,33	76470,10	74547,24
2022-09-30	68264,54	69960,31	68264,54	67196,91
2022-10-31	67545,31	66684,85	67545,31	67824,92
2022-11-30	68179,42	68736,84	67633,14	71285,42
2022-12-30	56963,32	54067,50	56390,98	60189,76

Таблиця 3.16.

Порівняння стратегій ребалансування (2022 рік).

Стратегія	Підсумкове значення	Максимальне значення	Мінімальне значення	Δ max	Δ final
MACD	54067,50	105072,29	51705,64	-5,8%	-5,08%
RSI	56390,98	105072,29	54296,01	-1,7%	-1%
S&R	60189,76	105072,29	57799,27	+7,9%	+5,66%
Buy&Hold	56963,32	105072,29	54816,37	-	-

За результатами експерименту на даних про зміну цін на фінансові інструменти за 2022 рік, найкращий кінцевий результат також показав портфель, який використовував для щотижневого ребалансування сигнали індикатора S&R. Його підсумкова вартість на \$3226,44 вища, ніж у портфеля buy-and-hold. Детальну розшифровку результатів роботи алгоритму ребалансування з використанням індикатора S&R на даних за 2022 рік подано в додатку Б.

Непередбачувані події, такі як війни чи стихійні лиха, мають помітний вплив на макроекономічні показники, часто призводячи до обвалу цін на різні фінансові інструменти. Однак важливо розуміти, що інвестиції в акції та інші цінні папери, як правило, спрямовані на довгострокове зростання, що вимагає ширшого вивчення загальної динаміки змін їхньої вартості протягом тривалих періодів. Наприклад, графік індексу S&P 500 за останні 15 років демонструє стійку тенденцію до зростання, що випереджає середній рівень інфляції. Навіть у складні часи пандемії COVID-19 у 2020 році для відновлення ціни індексу знадобилося 27 тижнів (з 10 лютого по 17 серпня). Згодом індекс демонстрував стійке зростання і наприкінці 2021 року досягнув історичного максимуму. Наразі рецесія, яка тривала від початку 2022 року, має ознаки завершення, що може свідчити про новий період зростання (рис. 3.13).



Рисунок 3.13. Графік індексу S&P 500 за останні 15 років [125].

Запропонований алгоритм ребалансування інвестиційного портфеля знижує ризик значної просадки вартості портфеля при зниженні вартості

окремих фінансових інструментів. Експерименти на основі даних про ціни на обрані фінансові інструменти за 2021 та 2022 роки показують, що алгоритм ребалансування краще працює з індикаторами S&R і RSI.

3.5 Розробка чат-боту для надання персональних фінансових рекомендацій

В ході виконання практичної частини дисертаційного дослідження було розроблено чат-бот для месенджеру Telegram, що використовує математичну модель сталого рівня споживання для визначення суми щорічних інвестицій, необхідних для забезпечення постійного рівня споживання протягом встановленого часу. Детальний опис моделі представлено в розділі 2.5 даної роботи.

Логіка роботи бота описана на рис. 3.14. Точкою входу в цей робочий процес є момент, коли користувач вперше відкриває діалог з ботом. Перше повідомлення містить загальну інформацію про те, що може робити цей бот та перелік доступних команд. Користувач може в будь-який момент виконати команду /start або /help, яка знову покаже цю інформацію.

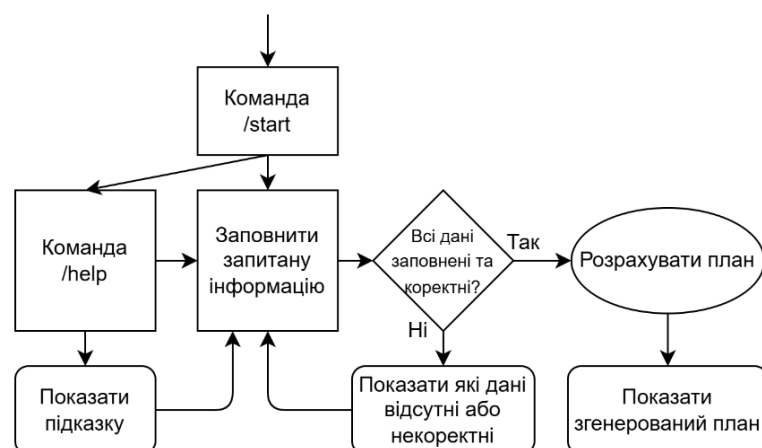


Рисунок 3.14. Схема роботи бота.

Після того як користувач виконає команду /help, він побачить, які дані йому потрібно заповнити. Після кожного введення дані перевіряються на стороні сервера. Якщо дані мають некоректний формат або не відповідають

встановленим обмеженням (наприклад, вік не може бути меншим за нуль), буде показано відповідне попередження. Останнім кроком є генерація плану постійного рівня споживання, який базується на інформації, наданій користувачем.

Обраний стек технологій дозволяє легко масштабувати та розширювати функціонал бота. Згідно з індексом TIOBE Programming Community, Java входить до трійки найпопулярніших мов програмування [98]. Розроблений додаток може бути розширений для інших месенджерів за допомогою бібліотек Java Bot або HTTP API (наприклад, Viber Java Bot API або Viber REST API) [126]. Бот був розроблений із використанням наступних мов програмування, фреймворків і бібліотек:

- Java – об'єктно-орієнтована мова програмування загального призначення.
- Spring Boot – Java-фреймворк для створення веб-додатків, який допомагає реалізувати архітектуру Model-View-Controller і легко запускати додаток всередині вбудованого Tomcat-сервера.
- Maven – інструмент автоматизації збірки для Java-проектів.
- TelegramBots-Spring-Boot-Starter – maven бібліотека, яка включає Telegram API та базову конфігурацію Spring Boot.

Після створення базового проекту Spring Boot потрібно створити новий клас, який буде розширювати абстрактний клас *TelegramLongPollingBot*. Клас *TelegramLongPollingBot* має три методи, які потрібно перевизначити та реалізувати. Основний метод, який викликається кожного разу, коли користувач надсилає повідомлення боту – це `public void onUpdateReceived(Update update)`. Він отримує об'єкт *Update*, який містить повідомлення та інформацію про його відправника.

Для того, щоб відправити повідомлення користувачеві, необхідно створити об'єкт *SendMessage*, задати ідентифікатор чату та текст

повідомлення, а також викликати метод `SendMessage.execute()`. Простий приклад реалізації методу `onUpdateReceived`, який просто реагує на будь-яке повідомлення від користувача, наведено на лістингу 3.10.

```
@Override
public void onUpdateReceived(Update update) {
    try {
        SendMessage sendMessage = new SendMessage();
        sendMessage.setChatId(String.valueOf(update.getMessage().getChatId()));
        sendMessage.setText("Hello, " + update.getMessage().getFrom().getUserName() + "!");
        execute(sendMessage);
    } catch (TelegramApiException e) {
        e.printStackTrace();
    }
}
```

Лістинг 3.10. Приклад реалізації методу `onUpdateReceived`.

Для того, щоб вказати, що наш Spring Boot-додаток повинен створити екземпляр (Spring-bean) класу, який реалізує методи Telegram Bot, потрібно додати до цього класу анотацію `@Component`. Ця анотація ініціює створення екземпляру класу під час ініціалізації контексту Spring-додатку.

На наступних рисунках (3.15-3.17) продемонстровано весь процес роботи з ботом, якого можна знайти в Telegram за іменем користувача [@FinAdviceBot](https://t.me/FinAdviceBot).

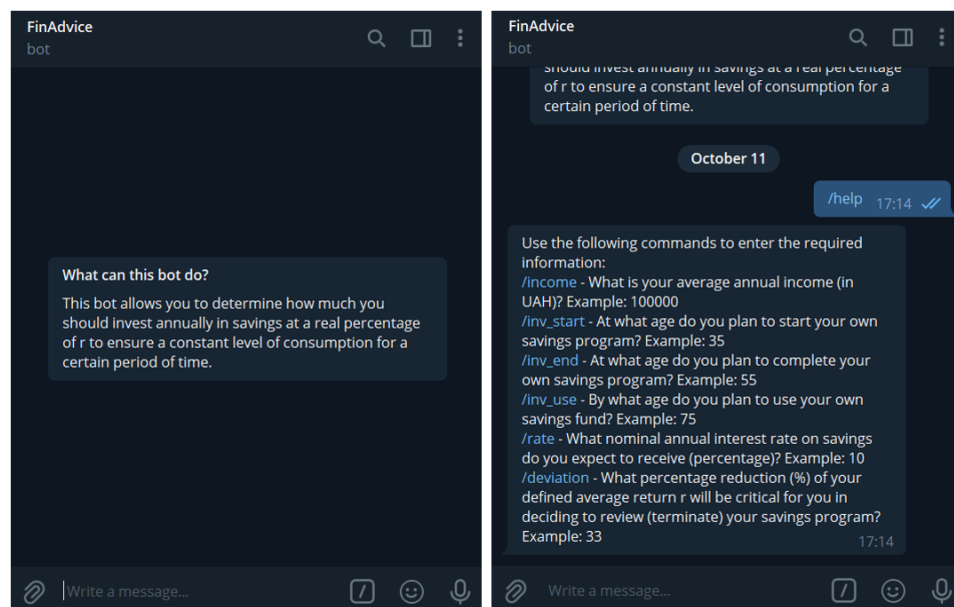


Рисунок 3.15. Початковий екран та вивід команди `/help`.

Підготуємо план заощаджень для забезпечення постійного рівня споживання з такими параметрами: річний дохід особи - 100000 грн.; вік, коли особа починає робити заощадження, - 35 років; вік, коли особа завершує

робити заощадження, - 60 років; вік, до якого особа планує витратити заощадження, - 80 років; очікувана номінальна річна відсоткова ставка по заощадженнях - 10%.

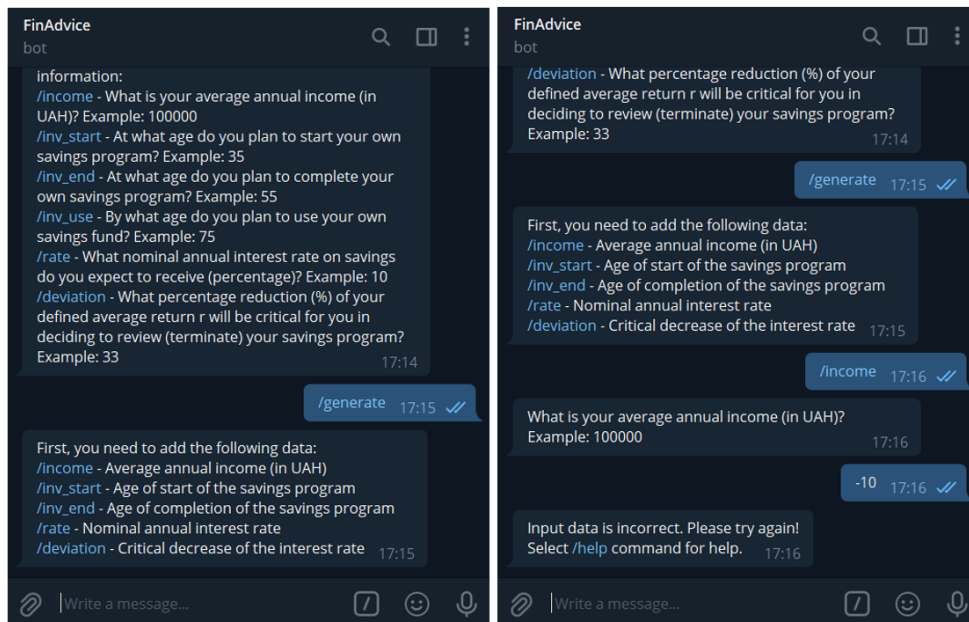


Рисунок 3.16. Приклади обробки вводу невалідних даних.

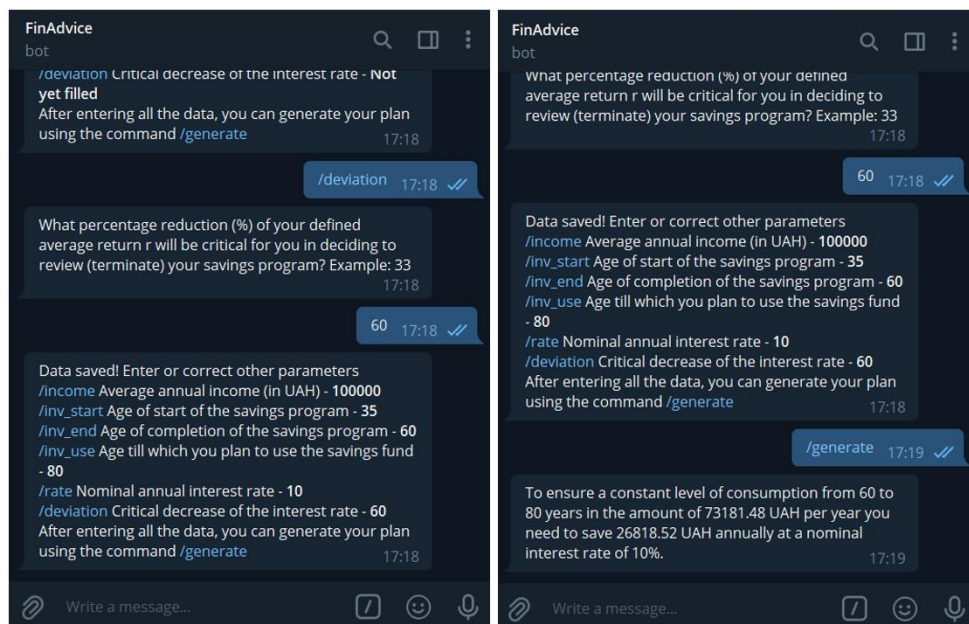


Рисунок 3.17. Приклад згенерованого плану.

Як бачимо, після виконання команди `/generate` бот розрахував, що для забезпечення постійного рівня споживання з 35 до 80 років у розмірі 73181 грн. необхідно відкладати 26818 грн. на рік при номінальній відсотковій ставці 10% та середньому рівні інфляції 6,3%.

Обраний підхід до створення чат-бота забезпечує максимальний рівень безпеки персональних даних користувачів. Як згадувалося раніше, безпека персональних даних є слабким місцем сторонніх сервісів, які дозволяють розробляти чат-ботів одразу для декількох месенджерів. На основі архітектури бота показано, що робочий процес бота досить зрозумілий, тому реалізація окремої версії для іншої месенджер-платформи не буде великим викликом.

Висновки до розділу 3

Однією з ключових частин даного дослідження є програмна реалізація модуля RA-системи, що забезпечує використання різних методів машинного навчання для прогнозування цін на фінансові інструменти та дозволяє порівняти їх ефективність. Результати експериментів показали, що нейронна мережа LSTM демонструє найкращі результати при прогнозуванні валютних пар, забезпечуючи похибку менше 0,5%. Метод множинної лінійної регресії виявився найбільш ефективним для прогнозування ціни закриття на основі ціни відкриття та обсягу торгів. Додатково було досліджено використання тижневих ковзних середніх (WMA), що, хоча і не призвело до суттєвого покращення точності прогнозів, проте дозволяє значно пришвидшити час виконання розрахунків.

На основі отриманих прогнозів було реалізовано алгоритм формування інвестиційного портфеля. Було розроблено програмний модуль, за допомогою якого проведено моделювання поведінки інвестиційних портфелів, складених з урахуванням прогнозованих цін на обрані фінансові інструменти та порівняно їх фінансові показники з портфелем, що складався, базуючись виключно на наявних історичних даних. Порівняльний аналіз портфелів продемонстрував, що портфель, побудований із урахуванням LSTM-прогнозів, показує найменшу різницю між очікуваною та реальною прибутковістю під час глобальної ринкової рецесії. Важливо відзначити, що

використання прогностичних даних дозволяє суттєво зменшити втрати портфеля в періоди ринкової нестабільності.

Також було проведено дослідження методу передбачення часток активів в початковому інвестиційному портфелі на основі профілю інвестора. Експериментальне порівняння різних алгоритмів машинного навчання показало, що моделі множинної лінійної регресії та випадкового лісу з автоматичним налаштуванням гіперпараметрів демонструють найкращі результати за метрикою RMSE. При цьому модель Random Forest досягла найвищої точності (46,27%) за результатами аналізу матриці помилок.

Одним із ключових аспектів реалізації RA-системи, що здатна ефективно управляти інвестиційним портфелем після його початкового формування, є реалізація модуля, що відповідає за аналіз поточної ринкової ситуації та виконує автоматичне ребалансування в разі потреби. Було запропоновано алгоритм автоматичного ребалансування портфеля на основі обробки сигналів різних фінансових індикаторів. Для підтвердження його ефективності було виконано його програмну реалізацію. Експериментальні результати показали, що стратегія ребалансування на основі індикатора Support and Resistance (S&R) демонструє найкращі результати як у 2021, так і в 2022 році. Зокрема, портфель з ребалансуванням на основі S&R показав прибутковість на 6,06% вищу порівняно зі стратегією "купи і тримай" у 2021 році. Важливо підкреслити, що розроблений алгоритм ефективно знижує ризик значної просадки вартості портфеля навіть під час глобальної ринкової рецесії, що продемонстрували експерименти з даними за 2022 рік.

Іншим практичним втіленням результатів дослідження стала реалізація чат-бота для надання персональних фінансових рекомендацій на базі месенджера Telegram з використанням мови програмування Java та фреймворком Spring Boot. Розроблено детальну схему взаємодії користувача з системою через інтерфейс месенджера та визначено механізми валідації введених даних і обробки помилок для забезпечення надійної роботи системи.

Розроблений бот забезпечує генерацію персоналізованих планів заощаджень, гарантує високий рівень безпеки персональних даних користувачів і має вбудовані можливості для масштабування та розширення функціоналу. Архітектура бота також передбачає можливість адаптації під інші месенджер-платформи.

Таким чином, у третьому розділі було успішно розроблено та протестовано ключові програмні модулі автоматизованої системи фінансового консультування. Проведені експерименти на практиці підтвердили ефективність запропонованих алгоритмів і методів для вирішення комплексу задач, пов'язаних з прогнозуванням, формуванням і ребалансуванням інвестиційного портфеля.

ЗАГАЛЬНІ ВИСНОВКИ

У дисертаційній роботі розглянуто актуальне науково-практичне завдання розробки автоматизованої інформаційної системи фінансового консультування для генерації персоналізованих інвестиційних портфелів. Проведений аналіз сучасного стану досліджень показав зростаючу потребу в автоматизованих системах фінансового консультування (Robo-Advisor), що зумовлено їх суттєвими перевагами порівняно з традиційними методами: доступністю, низьким порогом входу та можливістю точного налаштування параметрів формування інвестиційного портфелю. Особливої актуальності такі системи набувають в умовах високої інфляції, коли традиційні методи захисту заощаджень, такі як банківські депозити, не здатні компенсувати знецінення грошових коштів населення.

В рамках дослідження розроблено високорівневу архітектуру Robo-Advisor сервісу та комплексний методологічний підхід до створення системи автоматизованого фінансового консультування, який поєднує класичну модель Марковіца для формування оптимальних портфелів активів, сучасні методи машинного навчання для прогнозування цін на фінансові інструменти, модель забезпечення постійного рівня споживання для визначення довгострокових цілей інвестора та сучасні канали взаємодії з користувачами через месенджери. На основі запропонованого підходу розроблено архітектуру автоматизованої системи фінансового консультування, що базується на мікросервісному принципі та включає модулі формування інвестиційного портфелю, страхування, прогнозування прибутковості, сервісної логіки та обробки даних інтерфейсу користувача. Система реалізована з використанням сучасного стеку технологій для мов програмування Java та Python, що забезпечує необхідну гнучкість і можливості для масштабування.

Експериментальне дослідження ефективності різних методів машинного навчання для прогнозування цін на фінансові інструменти показало, що

нейронна мережа LSTM забезпечує найвищу точність прогнозування валютних пар з похибкою менше 0,5%. Метод множинної лінійної регресії виявився найбільш ефективним для прогнозування ціни закриття на основі ціни відкриття та обсягу торгів, а використання тижневих ковзних середніх (WMA) дозволяє значно пришвидшити час розрахунків без суттєвої втрати точності прогнозування.

Значним досягненням роботи є розробка та експериментальна перевірка алгоритму формування та ребалансування інвестиційного портфеля. Дослідження показали, що портфель, побудований з урахуванням LSTM-прогнозів, демонструє найменшу різницю між очікуваною та реальною прибутковістю. Особливо важливо відзначити, що стратегія ребалансування на основі індикатора Support and Resistance (S&R) показала прибутковість на 6,06% вищу порівняно зі стратегією "купи і тримай" у 2021 році, а розроблений алгоритм ефективно знижує ризик значної просадки вартості портфеля навіть під час глобальної ринкової рецесії.

Для вирішення задачі передбачення часток активів у початковому інвестиційному портфелі на основі профілю інвестора було проведено експериментальне порівняння різних алгоритмів машинного навчання. За результатами досліджень встановлено, що модель Random Forest з автоматичним налаштуванням гіперпараметрів досягає найвищої точності за результатами аналізу матриці помилок, що робить її оптимальним вибором для даної задачі.

Практичним втіленням результатів дослідження стала реалізація чат-бота для надання персональних фінансових рекомендацій на базі месенджера Telegram з використанням Java та Spring Boot. Розроблена система забезпечує генерацію персоналізованих планів заощаджень, гарантує високий рівень безпеки персональних даних користувачів та має вбудовані можливості для масштабування і розширення функціоналу, включаючи адаптацію під інші месенджер-платформи.

Таким чином, розроблені модулі автоматизованої інформаційної системи фінансового консультування, що поєднують використання класичної портфельної теорії Макровіца, аналіз ринкових даних та застосування сучасних методів машинного навчання, дозволяють ефективно вирішувати задачі формування та управління персоналізованими інвестиційними портфелями. Експериментальні дослідження підтвердили ефективність запропонованих підходів та алгоритмів, а практична реалізація системи у вигляді чат-бота забезпечує доступність фінансових консультацій для широкого кола користувачів.

Варто відзначити обмеження та перспективні напрямки подальшого розвитку дослідження. Зокрема, наразі в Україні існують певні регуляторні обмеження, які стоять на шляху повноцінної реалізації Robo-Advisor системи. Перш за все, мова йде про суттєві обмеження на доступ до закордонних інвестиційних платформ, пов'язані з дією військового стану через російське вторгнення. Це тимчасово звужує можливості практичного застосування системи та потребує адаптації до доступних в умовах воєнного стану фінансових інструментів. Крім того, з моменту початку дослідження у 2021 році відбувся стрімкий розвиток технології генеративних нейронних мереж, зокрема, великих мовних моделей (LLM), які зараз активно впроваджуються у фінансовій галузі, зокрема для аналізу ринкових настроїв, обробки фінансових новин і генерації персоналізованих інвестиційних рекомендацій. Оскільки на момент проведення основної частини дослідження ці технології не були настільки розвинені та доступні як зараз, питання їх інтеграції в систему фінансового консультування не було пріоритетним. Це відкриває перспективний напрямок для подальших досліджень, спрямованих на розширення функціональності системи за рахунок використання можливостей сучасних LLM для покращення якості фінансових рекомендацій і взаємодії з користувачами.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Consumer price indices for goods and services. State Statistics Service of Ukraine, https://www.ukrstat.gov.ua/operativ/operativ2010/ct/is_c/arh_isc/arh_iscm10_u.html, дата звернення 2023/05/05.
2. Lam, J. W., Robo-Advisors: A Portfolio Management Perspective. Yale College, New Haven, Connecticut, 2016.
3. Waliszewski, K., & Warchlewska, A. (2020). Financial technologies in personal financial planning: robo-advice vs. human-advice. *Ruch Prawniczy Ekonomiczny I Socjologiczny*, 82(4), 303–317. <https://doi.org/10.14746/rpeis.2020.82.4.22>
4. Maedche, A., Morana, S., Schacht, S., Werth, D., & Krumeich, J. (2016). Advanced User Assistance systems. *Business & Information Systems Engineering*, 58(5), 367–370. <https://doi.org/10.1007/s12599-016-0444-2>
5. Fein, M. L. (2015). Robo-Advisors: A closer look. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2658701>
6. Dorfleitner, G., Hornuf, L., Schmitt, M., & Weber, M. (2017). Definition of FinTech and Description of the FinTech Industry. In Springer eBooks (pp. 5–10). https://doi.org/10.1007/978-3-319-54666-7_2
7. Semenog, A. Y., Kryvykh, Y. M., Tsyrulyk, S. V., Fintech Services: Essence, Role And Value For The Economy Of The Country, *Odessa National University Herald. Economy*, 2(67) (2018), pp. 100–105.
8. Narayanan, A., As Robo Advisors Go Viral, Where Do Traditional Money Managers Go?, 2016. URL: <https://www.investors.com/etfs-and-funds/etfs/fund-industry-wakens-from-slumber-to-take-on-digital-advice-upstarts/>.
9. The Basel Committee on Banking Supervision, consultative document, Sound Practices: Implications of fintech developments for banks and bank supervisors / Bank for International Settlements, 2017. URL: <https://www.bis.org/bcbs/publ/d415.pdf>.

10. Waliszewski, K., & Zięba-Szklarska, M. (2020). Robo-advisors as Automated Personal Financial Planners – SWOT analysis. *Finanse I Prawo Finansowe*, 3(27), 155–173. <https://doi.org/10.18778/2391-6478.3.27.09>
11. Ivanov, O., Snihovyi, O., Kobets, V., Implementation of Robo-advisors tools for different risk attitude investment decisions, in: *Proceedings of the 14th International Conference on ICT in Education, Research and Industrial Applications. Integration, Harmonization and Knowledge Transfer, ICTERI 2018, CEUR-WS, volume 2104, Kyiv Ukraine, 2018, pp. 195–206. URL: https://ceur-ws.org/Vol-2104/paper_161.pdf.*
12. Kobets, V., Yatsenko, V., Mazur, A., Zubrii, M., Data analysis of private investment decision making using tools of Robo-advisers in long-run period, in: *Proceedings of the 14th International Conference on ICT in Education, Research and Industrial Applications. Integration, Harmonization and Knowledge Transfer, ICTERI 2018, CEUR-WS, volume 2104, Kyiv Ukraine, 2018, pp. 144–159. URL: https://ceur-ws.org/Vol-2104/paper_162.pdf.*
13. Marquit, M., Curry, B., How To Invest With a Robo-Advisor, 2021. URL: <https://www.forbes.com/advisor/investing/what-is-robo-advisor/>.
14. Snihovyi, O., Application of machine learning algorithms for forecasting the course of financial instruments under development of individual investment plans, Master's thesis, Kherson State University (KSU), Kherson, Ukraine, 2018.
15. Mavruk, T. (2022). Analysis of herding behavior in individual investor portfolios using machine learning algorithms. *Research in International Business and Finance*, 62, 101740. <https://doi.org/10.1016/j.ribaf.2022.101740>
16. Li, Y.-M., Lin, L.-F., & Hung, M.-C. (2024). A collective portfolio selection approach for investment clubs. *Information & Management*, 61(1), 103909. <https://doi.org/10.1016/j.im.2023.103909>

17. Silva, N. F., dos Santos, M., Gomes, C. F. S., & de Andrade, L. P. (2023). An integrated CRITIC and Grey Relational Analysis approach for investment portfolio selection. *Decision Analytics Journal*, 8, 100285. <https://doi.org/10.1016/j.dajour.2023.100285>
18. Silva, N. F., de Andrade, L. P., da Silva, W. S., de Melo, M. K., & Tonelli, A. O. (2024). Portfolio optimization based on the pre-selection of stocks by the Support Vector Machine model. *Finance Research Letters*, 61, 105014. <https://doi.org/10.1016/j.frl.2024.105014>
19. Dezhkam, A., & Manzuri, M. T. (2023). Forecasting stock market for an efficient portfolio by combining XGBoost and Hilbert-Huang transform. *Engineering Applications of Artificial Intelligence*, 118, 105626. <https://doi.org/10.1016/j.engappai.2022.105626>
20. Jareño, F., & Yousaf, I. (2023). Artificial intelligence-based tokens: Fresh evidence of connectedness with artificial intelligence-based equities. *International Review of Financial Analysis*, 89, 102826. <https://doi.org/10.1016/j.irfa.2023.102826>
21. Nguyen, H. H., Ngo, V. M., Le, T. T. P., & Nguyen, P. V. (2023). Do investors' personalities predict market winners? Experimental setting and machine learning analysis. *Heliyon*, 9(4), e15273. <https://doi.org/10.1016/j.heliyon.2023.e15273>
22. Sengupta, A., Jana, P., Dutta, P. N., & Mukherjee, I. (2024). Optimal stock allocation for an automated portfolio recommender system in the perspective of maximum fund utilization. *Expert Systems With Applications*, 242, 122857. <https://doi.org/10.1016/j.eswa.2023.122857>
23. Chen, W., Zhang, H., & Jia, L. (2022). A novel two-stage method for well-diversified portfolio construction based on stock return prediction using machine learning. *The North American Journal of Economics and Finance*, 63, 101818. <https://doi.org/10.1016/j.najef.2022.101818>

24. Abakah, E. J. A., Tiwari, A. K., Ghosh, S., & Dogan, B. (2023). Dynamic effect of Bitcoin, fintech and artificial intelligence stocks on eco-friendly assets, Islamic stocks and conventional financial markets: Another look using quantile-based approaches. *Technological Forecasting and Social Change*, 192, 122566. <https://doi.org/10.1016/j.techfore.2023.122566>
25. Ma, Y., Wang, Y., Wang, W., & Zhang, C. (2023). Portfolios with return and volatility prediction for the energy stock market. *Energy*, 270, 126958. <https://doi.org/10.1016/j.energy.2023.126958>
26. Lakshmi, K. V., & Kumara, K. N. U. (2024). A novel randomized weighted fuzzy AHP by using modified normalization with the TOPSIS for optimal stock portfolio selection model integrated with an effective sensitive analysis. *Expert Systems With Applications*, 243, 122770. <https://doi.org/10.1016/j.eswa.2023.122770>
27. Niu, Z., Wang, C., & Zhang, H. (2023). Forecasting stock market volatility with various geopolitical risks categories: New evidence from machine learning models. *International Review of Financial Analysis*, 89, 102738. <https://doi.org/10.1016/j.irfa.2023.102738>
28. Liao, S. H., Chu, P. H., & You, Y. L. (2011). Mining the co-movement between foreign exchange rates and category stock indexes in the Taiwan financial capital market. *Expert Systems with Applications*, 38(4), 4608-4617. <https://doi.org/10.1016/j.eswa.2010.09.134>
29. Chou, J.-S., & Chen, K.-E. (2024). Optimizing investment portfolios with a sequential ensemble of decision tree-based models and the FBI algorithm for efficient financial analysis. *Applied Soft Computing Journal*, 158, 111550. <https://doi.org/10.1016/j.asoc.2024.111550>
30. Jun, S. Y., Kim, D. S., Jung, S. Y., Jun, S. G., & Kim, J. W. (2022). Stock investment strategy combining earnings power index and machine learning.

International Journal of Accounting Information Systems, 47, 100576.
<https://doi.org/10.1016/j.accinf.2022.100576>

31. Morteza, H., Jameii, S. M., & Sohrabi, M. K. (2023). An improved learning automata based multi-objective whale optimization approach for multi-objective portfolio optimization in financial markets. Expert Systems With Applications, 224, 119970. <https://doi.org/10.1016/j.eswa.2023.119970>

32. Mirjalili, S., & Lewis, A. (2016). The Whale Optimization Algorithm. Advances in Engineering Software, 95, 51-67.
<https://doi.org/10.1016/j.advengsoft.2016.01.008>

33. Cui, T., Ding, S., Jin, H., & Zhang, Y. (2023). Portfolio constructions in cryptocurrency market: A CVaR-based deep reinforcement learning approach. Economic Modelling, 119, 106078. <https://doi.org/10.1016/j.econmod.2022.106078>

34. Behera, J., Pasayat, A. K., Behera, H., & Kumar, P. (2023). Prediction based mean-value-at-risk portfolio optimization using machine learning regression algorithms for multi-national stock markets. Engineering Applications of Artificial Intelligence, 120, 105843. <https://doi.org/10.1016/j.engappai.2023.105843>

35. Caparrini, A., Arroyo, J., & Mansilla, J. E. (2024). S&P 500 stock selection using machine learning classifiers: A look into the changing role of factors. Research in International Business and Finance, 70, 102336.
<https://doi.org/10.1016/j.ribaf.2024.102336>

36. Mahalakshmi, V., Kulkarni, N., Kumar, K. V. P., Kumar, K. S., Sree, D. N., & Durga, S. (2022). The Role of implementing Artificial Intelligence and Machine Learning Technologies in the financial services Industry for creating Competitive Intelligence. Materials Today: Proceedings, 56, 2252-2255.
<https://doi.org/10.1016/j.matpr.2021.11.577>

37. Pattnaik, D., Ray, S., & Raman, R. (2024). Applications of artificial intelligence and machine learning in the financial services industry: A bibliometric review. *Heliyon*, 10(1), e23492. <https://doi.org/10.1016/j.heliyon.2023.e23492>
38. Nazareth, N., & Ramana Reddy, Y. V. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*, 219, 119640. <https://doi.org/10.1016/j.eswa.2023.119640>
39. Ahmed, S., Alshater, M. M., El Ammari, A., & Hammami, H. (2022). Artificial intelligence and machine learning in finance: A bibliometric review. *Research in International Business and Finance*, 61, 101646. <https://doi.org/10.1016/j.ribaf.2022.101646>
40. Dakalbab, F., Abu Talib, M., Nasir, Q., & Saroufil, T. (2024). Artificial intelligence techniques in financial trading: A systematic literature review. *Journal of King Saud University - Computer and Information Sciences*, 36, 102015. <https://doi.org/10.1016/j.jksuci.2024.102015>
41. Goodell, J. W., Kumar, S., Lim, W. M., & Pattnaik, D. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32, 100577. <https://doi.org/10.1016/j.jbef.2021.100577>
42. Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications*, 197, 116659. <https://doi.org/10.1016/j.eswa.2022.116659>
43. Ashtiani, M. N., & Raahemi, B. (2023). News-based intelligent prediction of financial markets using text mining and machine learning: A systematic literature review. *Expert Systems with Applications*, 217, 119509. <https://doi.org/10.1016/j.eswa.2023.119509>

44. Gedikli, A., Sharma, G. D., Erdoğan, S., & Hammoudeh, S. (2024). Artificial intelligence, disruption of financial markets and natural resources economy in the digital era. *Resources Policy*, 92, 104953. <https://doi.org/10.1016/j.resourpol.2024.104953>
45. Ngo, V. M., Nguyen, H. H., & Nguyen, P. V. (2023). Does reinforcement learning outperform deep learning and traditional portfolio optimization models in frontier and developed financial markets? *Research in International Business and Finance*, 65, 101936. <https://doi.org/10.1016/j.ribaf.2023.101936>
46. Jiang, F., Ma, T., & Zhu, F. (2024). Fundamental characteristics, machine learning, and stock price crash risk. *Journal of Financial Markets*, 100908. <https://doi.org/10.1016/j.finmar.2024.100908>
47. Díaz, J. D., Hansen, E., & Cabrera, G. (2024). Machine-learning stock market volatility: Predictability, drivers, and economic value. *International Review of Financial Analysis*, 94, 103286. <https://doi.org/10.1016/j.irfa.2024.103286>
48. Chen, A. Y., & McCoy, J. (2024). Missing values handling for machine learning portfolios. *Journal of Financial Economics*, 155, 103815. <https://doi.org/10.1016/j.jfineco.2024.103815>
49. Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2023). Practical machine learning: Forecasting daily financial markets directions. *Expert Systems with Applications*, 233, 120840. <https://doi.org/10.1016/j.eswa.2023.120840>
50. Sheng, Y., Qu, Y., & Ma, D. (2024). Stock price crash prediction based on multimodal data machine learning models. *Finance Research Letters*, 62, 105195. <https://doi.org/10.1016/j.frl.2024.105195>
51. Sangeetha, J. M., & Alfia, K. J. (2024). Financial stock market forecast using evaluated linear regression based machine learning technique. *Measurement: Sensors*, 31, 100950. <https://doi.org/10.1016/j.measen.2023.100950>

52. Ren, X., Huang, Z., & He, Y. (2024). Financial warning for coal mining investments: Evidence from the fruit fly optimisation algorithm with backpropagation neural networks. *Energy Economics*, 134, 107594. <https://doi.org/10.1016/j.eneco.2024.107594>
53. Arian, H., Moghimi, M., Tabatabaei, E., & Zamani, S. (2022). Encoded Value-at-Risk: A machine learning approach for portfolio risk measurement. *Mathematics and Computers in Simulation*, 202, 500-525. <https://doi.org/10.1016/j.matcom.2022.07.015>
54. Gonzales, R. M. D., & Hargreaves, C. A. (2022). How can we use artificial intelligence for stock recommendation and risk management? A proposed decision support system. *International Journal of Information Management Data Insights*, 2(2), 100130. <https://doi.org/10.1016/j.jjime.2022.100130>
55. Dichtl, H., Drobetz, W., & Otto, T. (2023). Forecasting Stock Market Crashes via Machine Learning. *Journal of Financial Stability*, 65, 101099. <https://doi.org/10.1016/j.jfs.2022.101099>
56. Xu, Y., Dai, Y., Guo, L., & Chen, J. (2024). Leveraging machine learning to forecast carbon returns: Factors from energy markets. *Applied Energy*, 357, 122515. <https://doi.org/10.1016/j.apenergy.2023.122515>
57. Rubesam, A. (2022). Machine learning portfolios with equal risk contributions: Evidence from the Brazilian market. *Emerging Markets Review*, 51, 100891. <https://doi.org/10.1016/j.ememar.2022.100891>
58. Beniwal, M., Singh, A., & Kumar, N. (2024). Forecasting multistep daily stock prices for long-term investment decisions: A study of deep learning models on global indices. *Engineering Applications of Artificial Intelligence*, 129, 107617. <https://doi.org/10.1016/j.engappai.2023.107617>
59. Darwiesh, A., El-Baz, A. H., & Elhoseny, M. (2024). Intelligent risk management system for enhancing performance of stock market applications. *Expert*

Systems With Applications, 249, 123493.
<https://doi.org/10.1016/j.eswa.2024.123493>

60. Li, A., Liu, M., & Sheather, S.J. (2023). Predicting stock splits using ensemble machine learning and SMOTE oversampling. *Pacific-Basin Finance Journal*.
<https://doi.org/10.1016/j.pacfin.2023.101948>.

61. Ozbayoglu, A.M., Gudelek, M.U., & Sezer, O.B. (2020). Deep Learning for Financial Applications : A Survey. *Applied Soft Computing*, 93, 106384.
<https://doi.org/10.1016/j.asoc.2020.106384>.

62. Chhajer, P., Shah, M., & Kshirsagar, A. (2022). The applications of artificial neural networks, support vector machines, and long–short term memory for stock market prediction. *Decision Analytics Journal*, 2, 100015.
<https://doi.org/10.1016/j.dajour.2021.100015>.

63. Latif, S., Javaid, N., Aslam, F., Aldegheishem, A., Alrajeh, N., & Bouk, S. H. (2024). Enhanced prediction of stock markets using a novel deep learning model PLSTM-TAL in urbanized smart cities. *Heliyon*, 10(3), e27747.
<https://doi.org/10.1016/j.heliyon.2024.e27747>.

64. Lv, M., Wang, J., Wang, S., Gao, J., & Guo, H. (2024). Developing a hybrid system for stock selection and portfolio optimization with many-objective optimization based on deep learning and improved NSGA-III. *Information Sciences*, 670, 120549. <https://doi.org/10.1016/j.ins.2024.120549>.

65. Liu, X., Salem, S., Bian, L., Seong, J.-T., & Alshanbari, H. M. (2024). Application of machine learning algorithms in the domain of financial engineering. *Alexandria Engineering Journal*, 95, 94-100.
<https://doi.org/10.1016/j.aej.2024.03.058>.

66. Srivastava, T., Mullick, I., & Bedi, J. (2024). Association mining based deep learning approach for financial time-series forecasting. *Applied Soft Computing*, 155, 111469. <https://doi.org/10.1016/j.asoc.2024.111469>.

67. Pan, S., Long, S. (Cheng), Wang, Y., & Xie, Y. (2023). Nonlinear asset pricing in Chinese stock market: A deep learning approach. *International Review of Financial Analysis*, 87, 102627. <https://doi.org/10.1016/j.irfa.2023.102627>.
68. Li, J., Wang, X., Ahmad, S., Huang, X., & Khan, Y. A. (2023). Optimization of investment strategies through machine learning. *Heliyon*, 9(e16155). <https://doi.org/10.1016/j.heliyon.2023.e16155>.
69. Ying, Z., Cheng, D., Chen, C., Li, X., Zhu, P., Luo, Y., & Liang, Y. (2024). Predicting stock market trends with self-supervised learning. *Neurocomputing*, 568, 127033. <https://doi.org/10.1016/j.neucom.2023.127033>.
70. Ma, Y., Mao, R., Lin, Q., Wu, P., & Cambria, E. (2024). Quantitative stock portfolio optimization by multi-task learning risk and return. *Information Fusion*, 104, 102165. <https://doi.org/10.1016/j.inffus.2023.102165>.
71. Ma, C., & Nan, S. (2024). Dynamic graph reinforcement learning algorithm for portfolio management: A novel time–frequency correlated model. *Finance Research Letters*, 63, 105373. <https://doi.org/10.1016/j.frl.2024.105373>.
72. Zhu, Q., Zhou, X., & Liu, S. (2023). High return and low risk: Shaping composite financial investment decision in the new energy stock market. *Energy Economics*, 122, 106683. <https://doi.org/10.1016/j.eneco.2023.106683>.
73. Alzaman, C. (2024). Deep learning in stock portfolio selection and predictions. *Expert Systems With Applications*, 237, 121404. <https://doi.org/10.1016/j.eswa.2023.121404>.
74. Kamali Alamdari, M., Esfahanipour, A., & Dastkhan, H. (2024). A portfolio trading system using a novel pixel graph network for stock selection and a mean-CDaR optimization for portfolio rebalancing. *Applied Soft Computing*, 152, 111213. <https://doi.org/10.1016/j.asoc.2023.111213>.
75. Khang, P. Q., Kaczmarczyk, K., Tutak, P., Golec, P., Kuziak, K., Depczyński, R., Hernes, M., & Rot, A. (2021). Machine learning for liquidity prediction on

Vietnamese stock market. *Procedia Computer Science*, 192, 3590-3597.
<https://doi.org/10.1016/j.procs.2021.09.132>.

76. Yao, H., Xia, S., & Liu, H. (2022). Six-factor asset pricing and portfolio investment via deep learning: Evidence from Chinese stock market. *Pacific-Basin Finance Journal*, 76, 101886. <https://doi.org/10.1016/j.pacfin.2022.101886>.

77. Dong, L., Zheng, H., Li, L., & Zhou, C. (2024). Distilling wisdom of crowds in online communities: A novel prediction market constructed with comment posters. *Decision Support Systems*, 180, 114190. <https://doi.org/10.1016/j.dss.2024.114190>.

78. Kirtac, K., & Germano, G. (2024). Sentiment trading with large language models. *Finance Research Letters*, 62, 105227. <https://doi.org/10.1016/j.frl.2024.105227>.

79. Paiva, F.D., Cardoso, R.T., Hanaoka, G.P., & Duarte, W.M. (2019). Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. *Expert Systems with Applications*, 115, 635-655. <https://doi.org/10.1016/j.eswa.2018.08.003>.

80. Vo, N.N., He, X., Liu, S., & Xu, G. (2019). Deep learning for decision making and the optimization of socially responsible investments and portfolio. *Decision Support Systems*, 124. <https://doi.org/10.1016/j.dss.2019.113097>.

81. Grudniewicz, J., & Ślepaczuk, R. (2023). Application of machine learning in algorithmic investment strategies on global stock markets. *Research in International Business and Finance*, 66, 102052. <https://doi.org/10.1016/j.ribaf.2023.102052>.

82. Liu, M., Sun, W., Chen, J., & Ren, M. (2024). An automated quantitative investment model of stock selection and market timing based on industry information. *Egyptian Informatics Journal*, 26, 100471. <https://doi.org/10.1016/j.eij.2024.100471>.

83. Kuppenheimer, G., Shelly, S., & Strauss, J. (2023). Can machine learning identify sector-level financial ratios that predict sector returns? *Finance Research Letters*, 57, 104241. <https://doi.org/10.1016/j.frl.2023.104241>.
84. Jang, J., & Seong, N. (2023). Deep reinforcement learning for stock portfolio optimization by connecting with modern portfolio theory. *Expert Systems with Applications*, 218, 119556. <https://doi.org/10.1016/j.eswa.2023.119556>.
85. Niu, Z., Demirer, R., Suleman, M. T., Zhang, H., & Zhu, X. (2024). Do industries predict stock market volatility? Evidence from machine learning models. *Journal of International Financial Markets, Institutions & Money*, 90, 101903. <https://doi.org/10.1016/j.intfin.2023.101903>.
86. Zhao, C., Yuan, X., Long, J., Jin, L., & Guan, B. (2023). Financial indicators analysis using machine learning: Evidence from Chinese stock market. *Finance Research Letters*, 58, 104590. <https://doi.org/10.1016/j.frl.2023.104590>.
87. Lee, T. K., Cho, J. H., Kwon, D. S., & Sohn, S. Y. (2019). Global stock market investment strategies based on financial network indicators using machine learning techniques. *Expert Systems with Applications*, 117, 228-242. <https://doi.org/10.1016/j.eswa.2018.09.005>.
88. Sun, Q., Wei, X., & Yang, X. (2024). GraphSAGE with deep reinforcement learning for financial portfolio optimization. *Expert Systems with Applications*, 238, 122027. <https://doi.org/10.1016/j.eswa.2023.122027>.
89. Ayyildiz, N., & Iskenderoglu, O. (2024). How effective is machine learning in stock market predictions? *Heliyon*, 10(1), e24123. <https://doi.org/10.1016/j.heliyon.2024.e24123>.
90. Chen, M.-Y., Chen, C.-T., & Huang, S.-H. (2023). Knowledge distillation for portfolio management using multi-agent reinforcement learning. *Advanced Engineering Informatics*, 57, 102096. <https://doi.org/10.1016/j.aei.2023.102096>.

91. Hanauer, M. X. & Kalsbach, T. (2023). Machine learning and the cross-section of emerging market stock returns. *Emerging Markets Review*, 55, 101022. <https://doi.org/10.1016/j.ememar.2023.101022>.
92. Koratamaddi, P., Wadhwani, K., Gupta, M., & Sanjeevi, S. G. (2021). Market sentiment-aware deep reinforcement learning approach for stock portfolio allocation. *Engineering Science and Technology, an International Journal*, 24(4), 848-859. <https://doi.org/10.1016/j.jestch.2021.01.007>.
93. Cheng, L.-C., & Sun, J.-S. (2024). Multiagent-based deep reinforcement learning framework for multi-asset adaptive trading and portfolio management. *Neurocomputing*, 594, 127800. <https://doi.org/10.1016/j.neucom.2024.127800>.
94. Cui, T., Du, N., Yang, X., & Ding, S. (2024). Multi-period portfolio optimization using a deep reinforcement learning hyper-heuristic approach. *Technological Forecasting and Social Change*, 198, 122944. <https://doi.org/10.1016/j.techfore.2023.122944>.
95. Navarro, M. M., Young, M. N., Prasetyo, Y. T., & Taylar, J. V. (2023). Stock market optimization amidst the COVID-19 pandemic: Technical analysis, K-means algorithm, and mean-variance model (TAKMV) approach. *Heliyon*, 9(7), e17577. <https://doi.org/10.1016/j.heliyon.2023.e17577>.
96. Almeida, R. L. de, & Neves, R. F. (2022). Stock market prediction and portfolio composition using a hybrid approach combined with self-adaptive evolutionary algorithm. *Expert Systems With Applications*, 204, 117478. <https://doi.org/10.1016/j.eswa.2022.117478>.
97. Tiwari, A. K., Abakah, E. J. A., Abdullah, M., & Sulong, Z. (2023). What investors need to know about forecasting stock market return volatility using artificial intelligence. *Reference Collection in Social Sciences*. Elsevier. <https://doi.org/10.1016/B978-0-44-313776-1.00143-4>.

98. TIOBE Index for September 2022. URL: <https://www.tiobe.com/tiobe-index>, дата звернення 2022/10/12.
99. Project Pro: 15 Popular Machine Learning Frameworks to Manage Machine Learning Projects. URL: <https://www.projectpro.io/article/machine-learning-frameworks/509>, дата звернення 2022/10/12.
100. Kobets, V., Poltoratskiy, M., Using an Evolutionary Algorithm to Improve Investment Strategies for Industries in an Economic System, in: Proceedings of the 12th International Conference on ICT in Education, Research and Industrial Applications. Integration, Harmonization and Knowledge Transfer, ICTERI 2016, CEUR-WS, volume 1614, Kyiv Ukraine, 2016, pp. 485–501. URL: https://ceur-ws.org/Vol-1614/paper_102.pdf.
101. Musto, C., Semeraro, G., Lops, P., Degemmis, M., & Lekkas, G.P. (2015). Personalized finance advisory through case-based recommender systems and diversification strategies. Decision Support Systems, 77, 100-111. <https://doi.org/10.1016/j.dss.2015.06.001>.
102. Kobets, V., Savchenko, S. (2022). Building an Optimal Investment Portfolio with Python Machine Learning Tools. CEUR Workshop Proceedings, 3347, 307-315.
103. Savchenko, S., & Kobets, V. (2022). Development of software architecture and machine learning modules of Robo-Advisor System for personalized investment portfolio generation. In Communications in computer and information science (pp. 153–179). https://doi.org/10.1007/978-3-031-20834-8_8
104. Wakefield, K. A guide to the types of machine learning algorithms and their applications, https://www.sas.com/en_gb/insights/articles/analytics/machine-learning-algorithms.html, дата звернення 2024/10/10.

105. Geron, A., Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, O'Reilly Media, Inc, 2019.
106. Nelson, D. M. Q., Pereira, A. C. M., & De Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. 2022 International Joint Conference on Neural Networks (IJCNN), 1419–1426. <https://doi.org/10.1109/ijcnn.2017.7966019>
107. Wilder, J. W. New Concepts in Technical Trading Systems. Trend Research (1978).
108. Savchenko, S., Kobets, V.: Development of Robo-Advisor System for Personalized Investment and Insurance Portfolio Generation. In: Ermolayev, V. et al. (eds.) Proc. 17th Int. Conf. ICTERI, pp.488-500, CEUR-WS, Aachen University (2021).
109. Global social media stats, <https://datareportal.com/social-media-users>, дата звернення 2021/10/10.
110. Telegram Revenue and Usage Statistics, <https://www.businessofapps.com/data/telegram-statistics/>, дата звернення 2021/10/10.
111. Facebook Revenue and Usage Statistics, <https://www.businessofapps.com/data/facebook-statistics/>, дата звернення 2021/10/10.
112. WhatsApp Chatbot: The Complete Guide for 2021, <https://botscrew.com/blog/a-step-by-step-guide-to-create-chatbot-for-whatsapp-for-business/>, дата звернення 2021/10/10.
113. Ireland, D., Hassanzadeh, H., Tran, S.N. Sentimental Analysis for AIML-Based E-Health Conversational Agents. Neural Information Processing 2018. LNCS 11302, 41-51 (2018)

114. Lewis, D.R. The perils of overconfidence: Why many consumers fail to seek advice when they really should. *J Financ Serv Mark* 23, 104–111 (2018)
115. Janarthanam, S.: *Hands-On Chatbots and Conversational UI Development*. Packt Publishing, Birmingham, UK (2017).
116. Modrzyk, N.: *Building Telegram Bots: Develop Bots in 12 Programming Languages using the Telegram Bot API*. 1st edn. Apress (2019).
117. Trushar, B., Eytan, O.: *Guide to Chat Apps*. GitBooks (2015).
118. FAQ for the Technically Inclined, <https://core.telegram.org/techfaq>, дата звернення 2021/10/10.
119. 13Bots: An introduction for developers, <https://core.telegram.org/bots/samples>, дата звернення 2021/10/10.
120. 9 Best Chatbots in the Financial Services Industry, <https://www.haptik.ai/blog/best-chatbots-in-financial-industry>, дата звернення 2021/10/10.
121. Download historical data in Yahoo Finance. URL: <https://help.yahoo.com/kb/SLN2311.html>, дата звернення 2022/10/12.
122. Kobets, V., Yatsenko, V., Popovych, I. (2022). Automated Forming of Insurance Premium for Different Risk Attitude Investment Portfolio Using Robo-Advisor. *Communications in Computer and Information Science*, 1635 CCIS, 3–22. https://dx.doi.org/10.1007/978-3-031-14841-5_1.
123. Kolkova, A.: Comparison of trading systems based on technical analysis using real and random data. 21st International Scientific Conference Enterprise and Competitive Environment (2018).
124. Kobets, V., Petrov, O., Koval, S.: Sustainable Robo-Advisor Bot and Investment Advice-Taking Behavior. *Lecture Notes in Business Information Processing*, 465 LNBIP, pp. 15–35 (2022).

125. Yahoo Finance. Stock market news, quotes, and information. Yahoo Finance. URL: <https://finance.yahoo.com/>, дата звернення: 2024/11/12.
126. Viber API Documentation, <https://developers.viber.com/docs/api/java-bot-api>, дата звернення 2023/12/20.

ДОДАТКИ

Додаток А

Деталізація роботи алгоритму ребалансування інвестиційного портфелю з використанням індикатора S&R (2021 рік)

Початковий портфель: (('AAPL', 0.1135), ('AMD', 0.27372), ('AMZN', 0.11721), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.28702), ('TSLA', 0.20854), ('VOO', 0.0))

Розшифровка результатів ребалансування портфелю:

2021-01-08 Кандидати на продаж: ['TSLA'] Кандидати на купівлю: ['F', 'GOOG', 'INTC', 'MSFT']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-01-15 Кандидати на продаж: ['AMD', 'F', 'INTC', 'TSLA'] Кандидати на купівлю: ['AAPL', 'MSFT', 'NVDA']

Відібрані кандидати на продаж: {'F': 100, 'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-01-22 Кандидати на продаж: ['TSLA'] Кандидати на купівлю: ['AMD', 'F', 'MSFT']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-01-29 Кандидати на продаж: ['MS'] Кандидати на купівлю: ['F', 'GOOG', 'JPM', 'NVDA']

Відібрані кандидати на продаж: {'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-02-05 Кандидати на продаж: ['AMD', 'INTC', 'TSLA'] Кандидати на купівлю: ['F', 'GOOG']

Відібрані кандидати на продаж: {'AMD': 0.0, 'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-02-12 Кандидати на продаж: ['TSLA'] Кандидати на купівлю: ['F', 'GOOG', 'INTC']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-02-19 Кандидати на продаж: ['AMD'] Кандидати на купівлю: ['AAPL', 'F', 'GOOG']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-02-26 Кандидати на продаж: [] Кандидати на купівлю: ['AAPL', 'F', 'GOOG', 'INTC', 'TSLA']

Змін немає через відсутність кандидатів на продаж або покупку.

2021-03-05 Кандидати на продаж: ['AMD', 'TSLA'] Кандидати на купівлю: ['AAPL', 'F', 'GOOG', 'INTC', 'MS', 'NVDA']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-03-12 Кандидати на продаж: [] Кандидати на купівлю: ['AAPL', 'AMD', 'GOOG', 'INTC', 'NVDA']

Змін немає через відсутність кандидатів на продаж або покупку.

2021-03-19 Кандидати на продаж: ['AMD'] Кандидати на купівлю: ['AAPL', 'F', 'GOOG', 'MS', 'NVDA', 'TSLA']

Відібрані кандидати на продаж: {'AMD': 10.0}

Буде продано AMD та отримано \$ 2355.987927246094 після продажу (10.0 %)

Буде придбано NVDA

Поточний склад портфелю:(['AAPL', 0.11019387238593455), ('AMD', 0.22909153591997117), ('AMZN', 0.11794004813283751), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.33447987826859915), ('TSLA', 0.2075439000363771), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 92556.4153213501

2021-03-26 Кандидати на продаж: ['AMD', 'MS'] Кандидати на купівлю: ['AAPL', 'F', 'GOOG', 'NVDA', 'TSLA']

Відібрані кандидати на продаж: {'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-04-09 Кандидати на продаж: ['INTC', 'VOO'] Кандидати на купівлю: ['AMD', 'F', 'GOOG', 'MS', 'TSLA']

Відібрані кандидати на продаж: {'INTC': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-04-16 Кандидати на продаж: ['MS', 'VOO'] Кандидати на купівлю: ['AMD', 'F', 'GOOG']

Відібрані кандидати на продаж: {'MS': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-04-23 Кандидати на продаж: ['INTC', 'VOO'] Кандидати на купівлю: ['AMD', 'F', 'GOOG', 'MS']

Відібрані кандидати на продаж: {'INTC': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-04-30 Кандидати на продаж: ['AMZN', 'INTC', 'VOO'] Кандидати на купівлю: ['AMD', 'F', 'GOOG', 'MS']

Відібрані кандидати на продаж: {'INTC': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-05-07 Кандидати на продаж: ['AMD', 'INTC', 'MS', 'VOO'] Кандидати на купівлю: ['F', 'GOOG', 'TSLA']

Відібрані кандидати на продаж: {'AMD': 8.0, 'INTC': 100, 'MS': 100, 'VOO': 100}

Буде продано AMD та отримано \$ 1690.9473076171873 після продажу (8.0 %)

Буде придбано TSLA

Поточний склад портфелю:(['AAPL', 0.11136924954671468), ('AMD', 0.19567255736805447), ('AMZN', 0.11758143238260552), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.35920309915521836), ('TSLA', 0.21424598463614927), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 99379.77148742675

2021-05-14 Кандидати на продаж: ['MS', 'TSLA', 'VOO'] Кандидати на купівлю: ['AAPL', 'F', 'GOOG']

Відібрані кандидати на продаж: {'MS': 100, 'TSLA': 15.0, 'VOO': 100}

Буде продано TSLA та отримано \$ 2801.2650260925293 після продажу (15.0 %)

Буде придбано AAPL

Поточний склад портфелю:(['AAPL', 0.1466323928103487), ('AMD', 0.19606204285691622), ('AMZN', 0.12188254997242871), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.3656662106647733), ('TSLA', 0.1691017891214868), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 93871.47960009766

2021-05-21 Кандидати на продаж: ['AMD', 'MS', 'TSLA', 'VOO'] Кандидати на купівлю: ['AAPL', 'GOOG']

Відібрані кандидати на продаж: {'MS': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-05-28 Кандидати на продаж: ['INTC', 'VOO'] Кандидати на купівлю: ['AAPL', 'AMD', 'GOOG', 'MS', 'TSLA']

Відібрані кандидати на продаж: {'INTC': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-06-04 Кандидати на продаж: ['INTC', 'NVDA', 'TSLA', 'VOO'] Кандидати на купівлю: ['AAPL', 'AMD', 'GOOG']

Відібрані кандидати на продаж: {'INTC': 100, 'NVDA': 24.0, 'VOO': 100}

Буде продано NVDA та отримано \$ 10167.259870605469 після продажу (24.0 %)

Буде придбано AMD

Поточний склад портфелю:(['AAPL', 0.131164416339807), ('AMD', 0.29256927973258695), ('AMZN', 0.10980515481872596), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.31060419627321906), ('TSLA', 0.1555555085926393), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 103657.0764654541

2021-06-11 Кандидати на продаж: ['INTC', 'NVDA', 'VOO'] Кандидати на купівлю: ['AAPL', 'AMD', 'GOOG', 'MS', 'TSLA']

Відібрані кандидати на продаж: {'INTC': 100, 'NVDA': 12.0, 'VOO': 100}

Буде продано NVDA та отримано \$ 3917.8474016601563 після продажу (12.0 %)

Буде придбано AMD

Поточний склад портфелю:(['AAPL', 0.13104132192359888), ('AMD', 0.3251726503922357), ('AMZN', 0.11320030325086973), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.2737376335441445), ('TSLA', 0.15640777699047098), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 104957.73114395142

2021-06-18 Кандидати на продаж: ['AMZN', 'NVDA', 'VOO'] Кандидати на купівлю: ['GOOG', 'TSLA']

Відібрані кандидати на продаж: {'AMZN': 11.0, 'VOO': 100}

Буде продано AMZN та отримано \$ 1361.6344595336914 після продажу (11.0 %)

Буде придбано TSLA

Поточний склад портфелю:(['AAPL', 0.1294231426577583), ('AMD', 0.32637903670464474), ('AMZN', 0.10119723451551882), ('F', 0.0), ('GOOG', 0.0), ('INTC',

0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.2759566551511588), ('TSLA', 0.16556293675812997), ('VOO', 0.0))

Поточна вартість портфелю: \$ 108865.23411315918

2021-06-25 Кандидати на продаж: ['AMZN', 'MS', 'NVDA', 'VOO'] Кандидати на купівлю: ['GOOG', 'TSLA']

Відібрані кандидати на продаж: {'AMZN': 50.0, 'MS': 100, 'VOO': 100}

Буде продано AMZN та отримано \$ 5373.456373291016 після продажу (50.0 %)

Буде придбано TSLA

Поточний склад портфелю:(['AAPL', 0.129134264642602), ('AMD', 0.3228247230819031), ('AMZN', 0.048268164047856485), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.2755382929993509), ('TSLA', 0.22279979120800866), ('VOO', 0.0))

Поточна вартість портфелю: \$ 111325.06237368775

2021-07-02 Кандидати на продаж: ['AMZN', 'MSFT', 'VOO'] Кандидати на купівлю: ['GOOG', 'MS', 'NVDA', 'TSLA']

Відібрані кандидати на продаж: {'AMZN': 100, 'VOO': 100}

Буде продано AMZN та отримано \$ 5546.47052772522 після продажу (100 %)

Буде придбано NVDA

Поточний склад портфелю:(['AAPL', 0.12739135503513435), ('AMD', 0.33500146701818345), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.3249121220260596), ('TSLA', 0.21122267661936991), ('VOO', 0.0))

Поточна вартість портфелю: \$ 118655.46701288148

2021-07-09 Кандидати на продаж: ['AMZN', 'MSFT'] Кандидати на купівлю: ['AMD', 'GOOG', 'MS', 'NVDA', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-07-16 Кандидати на продаж: ['AMZN', 'MSFT', 'NVDA', 'VOO'] Кандидати на купівлю: ['MS', 'TSLA']

Відібрані кандидати на продаж: {'NVDA': 39.0, 'VOO': 100}

Буде продано NVDA та отримано \$ 13328.450929114015 після продажу (39.0 %)

Буде придбано TSLA

Поточний склад портфелю:(['AAPL', 0.14373540802857004), ('AMD', 0.3277598092720642), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.18952805557943256), ('TSLA', 0.33725594784970747), ('VOO', 0.0))

Поточна вартість портфелю: \$ 109994.60850272523

2021-07-23 Кандидати на продаж: ['AMZN', 'MSFT', 'NVDA'] Кандидати на купівлю: ['AMD', 'INTC', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-07-30 Кандидати на продаж: ['MSFT', 'NVDA'] Кандидати на купівлю: ['AMD', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-08-06 Кандидати на продаж: ['MS', 'MSFT'] Кандидати на купівлю: ['AMD', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-08-13 Кандидати на продаж: ['MSFT'] Кандидати на купівлю: ['AMD', 'MS', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-08-20 Кандидати на продаж: [] Кандидати на купівлю: ['AMD', 'F', 'INTC', 'MS', 'MSFT', 'NVDA', 'TSLA', 'VOO']

Змін немає через відсутність кандидатів на продаж або покупку.

2021-08-27 Кандидати на продаж: ['MSFT'] Кандидати на купівлю: ['AMD', 'MS', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2021-09-03 Кандидати на продаж: ['AMZN'] Кандидати на купівлю: ['AMD', 'F', 'MS', 'MSFT', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'AMZN': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-09-10 Кандидати на продаж: ['AMZN', 'MSFT'] Кандидати на купівлю: ['AMD', 'F', 'MS', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'AMZN': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-09-17 Кандидати на продаж: ['AMZN', 'MSFT'] Кандидати на купівлю: ['AMD', 'MS', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'AMZN': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-09-24 Кандидати на продаж: ['AMZN', 'MSFT'] Кандидати на купівлю: ['AMD', 'MS', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'AMZN': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-10-01 Кандидати на продаж: ['MS', 'MSFT', 'VOO'] Кандидати на купівлю: ['AMD', 'NVDA']

Відібрані кандидати на продаж: {'MS': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-10-08 Кандидати на продаж: ['JPM', 'MSFT'] Кандидати на купівлю: ['AMD', 'MS', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'JPM': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-10-15 Кандидати на продаж: ['AMZN', 'TSLA'] Кандидати на купівлю: ['AMD', 'MS', 'MSFT', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'AMZN': 100, 'TSLA': 15.0}

Буде продано TSLA та отримано \$ 7281.671878051758 після продажу (15.0 %)

Буде придбано AMD

Поточний склад портфелю:(['AAPL', 0.11457045475046376), ('AMD', 0.39888795355482654), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.18380418774066123), ('TSLA', 0.3022171794417824), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 136533.62586857384

2021-10-22 Кандидати на продаж: ['INTC', 'JPM'] Кандидати на купівлю: ['AMD', 'MS', 'MSFT', 'NVDA', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {'INTC': 100, 'JPM': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-10-29 Кандидати на продаж: ['F', 'INTC', 'TSLA'] Кандидати на купівлю: ['AMD', 'MS', 'VOO']

Відібрані кандидати на продаж: {'F': 100, 'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-11-05 Кандидати на продаж: ['AMZN', 'F', 'MS', 'NVDA'] Кандидати на купівлю: ['INTC', 'TSLA']

Відібрані кандидати на продаж: {'AMZN': 100, 'F': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-11-12 Кандидати на продаж: ['AMZN', 'F', 'MS'] Кандидати на купівлю: ['INTC', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'AMZN': 100, 'F': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-11-19 Кандидати на продаж: ['AMZN', 'F', 'INTC', 'TSLA'] Кандидати на купівлю: ['NVDA']

Відібрані кандидати на продаж: {'AMZN': 100, 'F': 100, 'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-11-26 Кандидати на продаж: ['AMZN', 'F', 'INTC', 'MS'] Кандидати на купівлю: ['MSFT', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'AMZN': 100, 'F': 100, 'INTC': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-12-03 Кандидати на продаж: ['F', 'INTC', 'MS'] Кандидати на купівлю: ['MSFT', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'F': 100, 'INTC': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-12-10 Кандидати на продаж: ['AAPL', 'AMZN', 'MS'] Кандидати на купівлю: ['F', 'INTC', 'NVDA']

Відібрані кандидати на продаж: {'AMZN': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2021-12-17 Кандидати на продаж: ['AAPL', 'AMZN', 'F', 'MS', 'NVDA'] Кандидати на купівлю: ['INTC', 'MSFT', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {'AMZN': 100, 'F': 100, 'MS': 100, 'NVDA': 50.0}

Буде продано NVDA та отримано \$ 15956.424543939454 після продажу (50.0 %)

Буде придбано TSLA

Поточний склад портфелю: (('AAPL', 0.11337692525928543), ('AMD', 0.41043883446267204), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.0978779751132692), ('TSLA', 0.3772403886525099), ('VOO', 0.0))

Поточна вартість портфелю: \$ 163023.64781733474

2021-12-31 Кандидати на продаж: ['AAPL', 'MS', 'NVDA'] Кандидати на купівлю: ['F', 'INTC']

Відібрані кандидати на продаж: {'MS': 100, 'NVDA': 37.0}

Буде продано NVDA та отримано \$ 6245.779435603604 після продажу (37.0 %)

Буде придбано F

Поточний склад портфелю: (('AAPL', 0.10907459086996614), ('AMD', 0.39755612137662744), ('AMZN', 0.0), ('F', 0.03650271856984674), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.060486115354071335), ('TSLA', 0.3963712832815487), ('VOO', 0.0))

Поточна вартість портфелю: \$ 175820.60714651918

Фінальний портфель "S&R ребалансування": (('AAPL', 0.10907459086996614), ('AMD', 0.39755612137662744), ('AMZN', 0.0), ('F', 0.03650271856984674), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.0), ('NVDA', 0.060486115354071335), ('TSLA', 0.3963712832815487), ('VOO', 0.0))

Вартість портфелю "купи і тримай" на кінець 2021 року складає \$ 165761.08

Вартість портфелю "S&R ребалансування" на кінець 2021 року складає \$ 175820.60

Додаток Б

Деталізація роботи алгоритму ребалансування інвестиційного портфелю з використанням індикатора S&R (2022 рік)

Початковий портфель: (('AAPL', 0.25899), ('AMD', 0.10384), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.25217), ('NVDA', 0.09699), ('TSLA', 0.288), ('VOO', 0.0))

Розшифровка результатів ребалансування портфелю:

 2022-01-07 Кандидати на продаж: ['AAPL', 'NVDA'] Кандидати на купівлю: ['MS', 'MSFT', 'VOO']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

 2022-01-14 Кандидати на продаж: ['AAPL', 'MS'] Кандидати на купівлю: ['MSFT', 'VOO']

Відібрані кандидати на продаж: {'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-01-21 Кандидати на продаж: ['MS', 'MSFT'] Кандидати на купівлю: ['AMD', 'F', 'INTC', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-01-28 Кандидати на продаж: ['AAPL', 'F', 'INTC', 'TSLA'] Кандидати на купівлю: ['AMD', 'MS', 'MSFT', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'F': 100, 'INTC': 100, 'TSLA': 11.0}

Буде продано TSLA та отримано \$ 2513.6595181274415 \$ після продажу (11.0 %)

Буде придбано AMD

Поточний склад портфелю: (('AAPL', 0.2861663872259712), ('AMD', 0.12803526274320912), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.26430682328908206), ('NVDA', 0.08468481315504142), ('TSLA', 0.23564771876701102), ('VOO', 0.0))

Поточна вартість портфелю: \$ 86305.9093170166

 2022-02-04 Кандидати на продаж: ['AAPL', 'F', 'INTC'] Кандидати на купівлю: ['AMD', 'MS', 'MSFT', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {'F': 100, 'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-02-11 Кандидати на продаж: ['F', 'INTC', 'MSFT', 'TSLA'] Кандидати на купівлю: ['AMD', 'MS', 'VOO']

Відібрані кандидати на продаж: {'F': 100, 'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-02-18 Кандидати на продаж: ['F', 'MSFT', 'TSLA', 'VOO'] Кандидати на купівлю: ['AMD']

Відібрані кандидати на продаж: {'F': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-02-25 Кандидати на продаж: ['F', 'INTC', 'MSFT'] Кандидати на купівлю: ['AMD', 'VOO']

Відібрані кандидати на продаж: {'F': 100, 'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-03-04 Кандидати на продаж: ['INTC', 'MSFT', 'TSLA', 'VOO'] Кандидати на купівлю: ['AMD', 'NVDA']

Відібрані кандидати на продаж: {'INTC': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-03-11 Кандидати на продаж: ['MSFT', 'VOO'] Кандидати на купівлю: ['AMD', 'JPM', 'NVDA']

Відібрані кандидати на продаж: {'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-03-18 Кандидати на продаж: ['INTC'] Кандидати на купівлю: ['AMD', 'MSFT', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-03-25 Кандидати на продаж: ['AAPL', 'NVDA'] Кандидати на купівлю: ['AMD', 'INTC', 'MS', 'MSFT', 'VOO']

Відібрані кандидати на продаж: {'AAPL': 31.0}

Буде продано AAPL та отримано \$ 7853.6640548706055 \$ після продажу (31.0 %)

Буде придбано AMD

Поточний склад портфелю: [('AAPL', 0.18672166446200872), ('AMD', 0.21858300280231366), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.24003959925971335), ('NVDA', 0.09465407492006961), ('TSLA', 0.25940912767396), ('VOO', 0.0)]

Поточна вартість портфелю: \$ 93619.21752624512

2022-04-01 Кандидати на продаж: ['AAPL', 'INTC'] Кандидати на купівлю: ['AMD', 'MSFT', 'VOO']

Відібрані кандидати на продаж: {'AAPL': 1.0, 'INTC': 100}

Буде продано AAPL та отримано \$ 174.39715255737306 \$ після продажу (1.0 %)

Буде придбано AMD

Поточний склад портфелю: [('AAPL', 0.1846492986652916), ('AMD', 0.20017337508898733), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.2448799333840007), ('NVDA', 0.09141752401080705), ('TSLA', 0.2787356020098419), ('VOO', 0.0)]

Поточна вартість портфелю: \$ 93503.29640014649

2022-04-08 Кандидати на продаж: ['AAPL', 'INTC', 'MSFT'] Кандидати на купівлю: ['AMD', 'VOO']

Відібрані кандидати на продаж: {'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-04-22 Кандидати на продаж: ['AMD', 'MSFT', 'NVDA', 'VOO'] Кандидати на купівлю: ['GOOG', 'JPM']

Відібрані кандидати на продаж: {'AMD': 93.0, 'VOO': 100}

Буде продано AMD та отримано \$ 14180.844501800539 \$ після продажу (93.0 %)

Буде придбано GOOG

Поточний склад портфелю: (('AAPL', 0.1955217681481632), ('AMD', 0.013022919552303386), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.1722087390763233), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.24741213670114062), ('NVDA', 0.07619205580327974), ('TSLA', 0.29466774859324957), ('VOO', 0.0)])
 Поточна вартість портфелю: \$ 81961.29818062592

 2022-04-29 Кандидати на продаж: ['MSFT', 'NVDA', 'TSLA', 'VOO'] Кандидати на купівлю: ['AMZN', 'GOOG', 'JPM', 'MS']

Відібрані кандидати на продаж: {'TSLA': 9.0, 'VOO': 100}

Буде продано TSLA та отримано \$ 1883.1926071197508 \$ після продажу (9.0 %)

Буде придбано AMZN

Поточний склад портфелю: (('AAPL', 0.20098633462334645), ('AMD', 0.013330059947618893), ('AMZN', 0.023994849800266733), ('F', 0.0), ('GOOG', 0.17461180390828102), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.2643298890023128), ('NVDA', 0.07639130643883031), ('TSLA', 0.2450834062602201), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 77692.61079223633

 2022-05-06 Кандидати на продаж: ['MSFT', 'NVDA', 'TSLA', 'VOO'] Кандидати на купівлю: ['AMZN', 'GOOG', 'JPM']

Відібрані кандидати на продаж: {'NVDA': 100, 'VOO': 100}

Буде продано NVDA та отримано \$ 5976.0 \$ після продажу (100 %)

Буде придбано GOOG

Поточний склад портфелю: (('AAPL', 0.2011769210226589), ('AMD', 0.014909794114296014), ('AMZN', 0.022232150289316476), ('F', 0.0), ('GOOG', 0.25391274201652575), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.26253680495744874), ('NVDA', 0.0), ('TSLA', 0.2444498924318839), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 77436.84096514893

 2022-05-13 Кандидати на продаж: ['NVDA'] Кандидати на купівлю: ['AMZN', 'GOOG', 'JPM', 'MS']

Відібрані кандидати на продаж: {'NVDA': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-05-20 Кандидати на продаж: ['MS'] Кандидати на купівлю: ['AMZN', 'F', 'GOOG', 'INTC', 'JPM', 'TSLA']

Відібрані кандидати на продаж: {'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-05-27 Кандидати на продаж: ['MSFT', 'NVDA', 'VOO'] Кандидати на купівлю: ['AMD', 'AMZN', 'GOOG']

Відібрані кандидати на продаж: {'NVDA': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-06-03 Кандидати на продаж: ['MSFT', 'NVDA', 'VOO'] Кандидати на купівлю: ['AMD', 'AMZN', 'GOOG']

Відібрані кандидати на продаж: {'NVDA': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-06-10 Кандидати на продаж: ['INTC', 'MS'] Кандидати на купівлю: ['AMZN', 'F', 'GOOG', 'JPM']

Відібрані кандидати на продаж: {'INTC': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-06-17 Кандидати на продаж: [] Кандидати на купівлю: ['AMD', 'AMZN', 'F', 'GOOG', 'JPM', 'MS', 'TSLA']

Змін немає через відсутність кандидатів на продаж або покупку.

 2022-06-24 Кандидати на продаж: ['AMD', 'INTC', 'MS', 'NVDA'] Кандидати на купівлю: ['AMZN', 'F', 'GOOG', 'JPM']

Відібрані кандидати на продаж: {'INTC': 100, 'MS': 100, 'NVDA': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-07-01 Кандидати на продаж: [] Кандидати на купівлю: ['AMZN', 'F', 'GOOG', 'JPM', 'TSLA']

Змін немає через відсутність кандидатів на продаж або покупку.

 2022-07-08 Кандидати на продаж: ['AMD', 'INTC'] Кандидати на купівлю: ['AMZN', 'F', 'GOOG', 'JPM']

Відібрані кандидати на продаж: {'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-07-15 Кандидати на продаж: ['INTC', 'MS'] Кандидати на купівлю: ['AMD', 'AMZN', 'F', 'GOOG', 'JPM']

Відібрані кандидати на продаж: {'INTC': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-07-22 Кандидати на продаж: ['AMD', 'INTC', 'NVDA', 'TSLA'] Кандидати на купівлю: ['AMZN', 'F', 'GOOG', 'JPM', 'MS']

Відібрані кандидати на продаж: {'INTC': 100, 'NVDA': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-07-29 Кандидати на продаж: ['MSFT', 'NVDA', 'TSLA', 'VOO'] Кандидати на купівлю: ['GOOG', 'JPM']

Відібрані кандидати на продаж: {'NVDA': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-08-05 Кандидати на продаж: ['MSFT', 'NVDA', 'TSLA', 'VOO'] Кандидати на купівлю: ['AMD', 'GOOG', 'JPM']

Відібрані кандидати на продаж: {'NVDA': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-08-12 Кандидати на продаж: ['AAPL', 'MSFT', 'NVDA', 'VOO'] Кандидати на купівлю: ['AMD', 'GOOG', 'JPM', 'MS', 'TSLA']

Відібрані кандидати на продаж: {'NVDA': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-08-19 Кандидати на продаж: ['AAPL', 'MSFT', 'NVDA', 'TSLA', 'VOO'] Кандидати на купівлю: ['GOOG', 'JPM', 'MS']

Відібрані кандидати на продаж: {'NVDA': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

 2022-08-26 Кандидати на продаж: ['TSLA', 'VOO'] Кандидати на купівлю: ['AMD', 'GOOG', 'JPM']

Відібрані кандидати на продаж: {'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-09-02 Кандидати на продаж: ['TSLA'] Кандидати на купівлю: ['AMD', 'AMZN', 'GOOG', 'INTC', 'JPM']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2022-09-09 Кандидати на продаж: ['MS', 'TSLA', 'VOO'] Кандидати на купівлю: ['GOOG', 'INTC', 'JPM']

Відібрані кандидати на продаж: {'MS': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-09-16 Кандидати на продаж: ['INTC', 'MS'] Кандидати на купівлю: ['AMZN', 'GOOG', 'JPM', 'TSLA']

Відібрані кандидати на продаж: {'INTC': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-09-23 Кандидати на продаж: ['AMD', 'GOOG', 'INTC', 'TSLA'] Кандидати на купівлю: ['AMZN', 'F', 'JPM', 'MS', 'NVDA']

Відібрані кандидати на продаж: {'GOOG': 100, 'INTC': 100}

Буде продано GOOG та отримано \$ 16858.899688720703 \$ після продажу (100 %)

Буде придбано NVDA

Поточний склад портфелю:(['AAPL', 0.2128044895017863), ('AMD', 0.011754159279968857), ('AMZN', 0.024375371749433918), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.25145294800005813), ('NVDA', 0.24132004615398112), ('TSLA', 0.2579669063538614), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 70017.39293387756

2022-09-30 Кандидати на продаж: ['MS'] Кандидати на купівлю: ['AMZN', 'F', 'JPM', 'NVDA', 'VOO']

Відібрані кандидати на продаж: {'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-10-07 Кандидати на продаж: ['AMD', 'GOOG', 'MS'] Кандидати на купівлю: ['AMZN', 'F', 'JPM', 'NVDA', 'TSLA']

Відібрані кандидати на продаж: {'GOOG': 100, 'MS': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-10-14 Кандидати на продаж: ['GOOG'] Кандидати на купівлю: ['AMZN', 'F', 'JPM', 'MSFT', 'NVDA', 'TSLA', 'VOO']

Відібрані кандидати на продаж: {'GOOG': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-10-21 Кандидати на продаж: ['AMD', 'MS'] Кандидати на купівлю: ['AMZN', 'F', 'GOOG', 'JPM', 'NVDA', 'TSLA']

Відібрані кандидати на продаж: {'AMD': 100, 'MS': 100}

Буде продано AMD та отримано \$ 712.3101963043205 \$ після продажу (100 %)

Буде придбано TSLA

Поточний склад портфелю:(['AAPL', 0.22126483978145808), ('AMD', 0.0), ('AMZN', 0.027148780313190023), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.2717741817254742), ('NVDA', 0.25527408277975283), ('TSLA', 0.2231453124671351), ('VOO', 0.0)])

Поточна вартість портфелю: \$ 65925.61340786285

2022-10-28 Кандидати на продаж: ['INTC'] Кандидати на купівлю: ['AMD', 'AMZN', 'JPM', 'MS', 'TSLA']

Відібрані кандидати на продаж: {'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-11-04 Кандидати на продаж: ['INTC'] Кандидати на купівлю: ['AMD', 'AMZN', 'MSFT', 'TSLA']

Відібрані кандидати на продаж: {'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-11-11 Кандидати на продаж: ['TSLA'] Кандидати на купівлю: ['AMD', 'AMZN', 'INTC', 'MS']

Відібрані кандидати на продаж: {}

Змін немає так як усі кандидати на продаж не пройшли перевірку.

2022-11-18 Кандидати на продаж: ['GOOG', 'INTC', 'MS', 'TSLA'] Кандидати на купівлю: []

Змін немає через відсутність кандидатів на продаж або покупку.

2022-11-25 Кандидати на продаж: ['GOOG', 'INTC', 'TSLA'] Кандидати на купівлю: ['MS']

Відібрані кандидати на продаж: {'GOOG': 100, 'INTC': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-12-02 Кандидати на продаж: ['INTC', 'TSLA', 'VOO'] Кандидати на купівлю: ['GOOG', 'MS']

Відібрані кандидати на продаж: {'INTC': 100, 'VOO': 100}

Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

2022-12-09 Кандидати на продаж: ['AMD', 'AMZN', 'INTC', 'MS', 'NVDA', 'TSLA']

Кандидати на купівлю: []

Змін немає через відсутність кандидатів на продаж або покупку.

2022-12-16 Кандидати на продаж: ['AMZN'] Кандидати на купівлю: ['F', 'GOOG', 'JPM']

Відібрані кандидати на продаж: {'AMZN': 100}

Буде продано AMZN та отримано \$ 1317.9000091552734 \$ після продажу (100 %)

Буде придбано GOOG

Поточний склад портфелю: (('AAPL', 0.2033545424961942), ('AMD', 0.0), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.02080228441894453), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.2763725976512233), ('NVDA', 0.34145190411774107), ('TSLA', 0.15730402474053135), ('VOO', 0.0))

Поточна вартість портфелю: \$ 65516.84332871094

2022-12-23 Кандидати на продаж: ['GOOG'] Кандидати на купівлю: ['F', 'TSLA']

Відібрані кандидати на продаж: {'GOOG': 100}

Буде продано GOOG та отримано \$ 1347.1499633789062 \$ після продажу (100 %)

Буде придбано TSLA

Поточний склад портфелю: (('AAPL', 0.2137690822351617), ('AMD', 0.0), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.28914670107136864), ('NVDA', 0.3359914913031416), ('TSLA', 0.1604491376269087), ('VOO', 0.0))

Поточна вартість портфелю: \$ 61097.08192547379

 2022-12-30 Кандидати на продаж: ['GOOG'] Кандидати на купівлю: ['AAPL', 'F', 'TSLA']
 Відібрані кандидати на продаж: {'GOOG': 100}
 Змін немає тому що кандидати на продаж зараз не присутні в портфелі.

Фінальний портфель "S&R ребалансування": ([('AAPL', 0.2137690822351617), ('AMD', 0.0), ('AMZN', 0.0), ('F', 0.0), ('GOOG', 0.0), ('INTC', 0.0), ('JPM', 0.0), ('MS', 0.0), ('MSFT', 0.28914670107136864), ('NVDA', 0.3359914913031416), ('TSLA', 0.1604491376269087), ('VOO', 0.0)])

Вартість портфелю "купи і тримай" на кінець 2022 року складає \$ 56963.31

Вартість портфелю "S&R ребалансування" на кінець 2022 року складає \$ 60189.76