

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Центр _____ Післядипломної освіти
(повна назва)

Кафедра _____ Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА Пояснювальна записка

рівень вищої освіти _____ другий (магістерський)

Дослідження методів машинного навчання для автоматизації
ведення особистих фінансів та торгівлі на фінансових ринках
(тема)

Виконав:
здобувач _____ другого _____ року навчання,
групи _____ СШІмзд-23-1

_____ Микола Черкасов
(власне ім'я, прізвище)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)

Тип програми _____ освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи штучного інтелекту
(повна назва освітньої програми)

Керівник _____ проф. Сергій Удовенко
(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ШІ

(підпис)

_____ Олег ЗОЛОТУХІН
(власне ім'я, прізвище)

Харківський національний університет радіоелектроніки

Центр _____ Післядипломної освіти _____

Кафедра _____ Штучного інтелекту _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 122 Комп'ютерні науки _____
(код і повна назва)

Тип програми _____ освітньо-наукова _____
(освітньо-професійна або освітньо-наукова)

Освітня програма _____ Системи штучного інтелекту _____
(повна назва)

ЗАТВЕРДЖУЮ:
Зав. кафедри _____
(підпис)
«_____» _____ 20__ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ Черкасову Миколі Миколайовичу _____
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Дослідження методів машинного навчання для автоматизації ведення особистих фінансів та торгівлі на фінансових ринках _____

затверджена наказом університету від 21 квітня 2025 р. № 62Стз

2. Термін подання студентом роботи до екзаменаційної комісії 3 червня 2025 р.

3. Вихідні дані до роботи набори реальних або змодельованих транзакційних даних користувачів, що включають інформацію про доходи, витрати за різними категоріями, заощадження, інвестиції, кредити; історичні котирування цін на різні фінансові інструменти (акції, облігації, валюти, сировинні товари, криптовалюти тощо), новини та настрої ринку; наукові публікації, статті, книги та звіти аналітичних агентств, результати попередніх досліджень, описи існуючих програмних продуктів та сервісів

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Теоретичні та методологічні основи машинного навчання у фінансовій сфері _____

2) Обґрунтування вибору напрямку дослідження та методів розв'язання задачі _____

3) Розробка алгоритмів машинного навчання для автоматизації ведення особистих фінансів _____

4) Розробка алгоритмів машинного навчання для торгівлі на фінансових ринках _____

5) Узагальнення результатів та перспективи розвитку _____

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / терміни виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	21.04.2025	виконано
2	Бібліографічний пошук	23.04.2025	виконано
3	Розробка основних положень роботи	24.04.2025	виконано
4	Написання I розділу	25.04.2025	виконано
5	Написання II розділу	28.04.2025	виконано
6	Написання III розділу	30.04.2025	виконано
7	Написання IV розділу	02.05.2025	виконано
8	Написання V розділу	05.05.2025	виконано
9	Систематизація висновків	07.05.2025	виконано
10	Редагування тексту науковим керівником	09.05.2025	виконано
11	Нормоконтроль	12.05.2025	виконано
12	Підготовка відгуку наукового керівника	12.05.2025	виконано
13	Підготовка зовнішньої рецензії	12.05.2025	виконано
14	Подання чистового варіанта роботи	12.05.2025	виконано
15	Захист роботи	03.06.2025	

Дата видачі завдання 21 квітня 2025 р.

Здобувач _____

(підпис)

Керівник роботи _____

(підпис)

проф. Сергій Удовенко

(посада, власне ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка: 95 с., 6 рис., 1 табл., 7 дод., 34 джерела.

КЛАСИФІКАЦІЯ, МАШИННЕ НАВЧАННЯ, НЕЙРОННІ МЕРЕЖІ, ОСОБИСТІ ФІНАНСИ, ПРОГНОЗУВАННЯ, ТРЕЙДИНГ, ФІНАНСОВЕ МОДЕЛЮВАННЯ, ФІНАНСОВІ РИНКИ, ЧАСОВІ РЯДИ.

Об'єкт дослідження – процеси автоматизованого аналізу фінансових даних з метою оптимізації особистих фінансів та прийняття торгових рішень на фінансових ринках.

Предмет дослідження – алгоритми машинного навчання, які застосовуються до задач прогнозування витрат, аналізу транзакцій та побудови торгових стратегій.

Мета роботи – розроблення, аналіз та програмна реалізація моделей машинного навчання, спрямованих на покращення ефективності управління особистими фінансами та прийняття рішень при торгівлі на ринках.

Методи дослідження – методи машинного навчання; методи статистичного аналізу фінансових даних; методи побудови та програмної реалізації нейромережових моделей з використанням Python, бібліотек Scikit-learn, Pandas, TensorFlow тощо.

У роботі розглядається застосування методів машинного навчання для автоматизації ведення особистих фінансів і прийняття рішень у сфері торгівлі на фінансових ринках. Реалізовано програмний прототип, який дозволяє апробувати досліджувані методи на реальних і синтетичних даних. Результати показали доцільність застосування моделей машинного навчання. Робота має практичну цінність і може бути використана як основа для подальших досліджень у сфері фінансових технологій.

ABSTRACT

Master's thesis contains: 95 p., 6 fig., 1 tabl., 7 ann., 34 references.

CLASSIFICATION, FINANCIAL MARKETS, FINANCIAL MODELING, FORECASTING, MACHINE LEARNING, NEURAL NETWORKS, PERSONAL FINANCE, TIME SERIES, TRADING.

Object of research: the processes of automated analysis of financial data for the purpose of optimizing personal finance and making trading decisions in financial markets.

Subject of research: machine learning algorithms applied to problems of expenditure forecasting, transaction analysis, and the construction of trading strategies.

Goal of the work: the development, analysis, and software implementation of machine learning models aimed at improving the efficiency of personal finance management and decision-making when trading in markets.

Research methods: machine learning methods; methods of statistical analysis of financial data; methods of building and software implementation of neural network models using Python, libraries such as Scikit-learn, Pandas, TensorFlow, etc.

This work examines the application of machine learning methods for automating personal finance management and decision-making in the field of trading on financial markets. A software prototype has been implemented that allows testing the studied methods on real and synthetic data. The results showed the feasibility of applying machine learning models. The work has practical value and can be used as a basis for further research in the field of financial technologies.

ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів	8
Вступ.....	10
1 Теоретичні та методологічні основи машинного навчання у фінансовій сфері.....	13
1.1 Сучасний стан проблеми автоматизації особистих фінансів та торгівлі на фінансових ринках	13
1.2 Огляд алгоритмів машинного навчання в аналізі фінансових даних	15
1.3 Тенденції розвитку машинного навчання у фінансових технологіях	20
1.4 Фактори, що впливають на зростаюче значення машинного навчання у фінансах.....	24
1.5 Постановка задачі.....	27
2 Обґрунтування вибору напрямку дослідження та методів розв'язання задачі.....	29
2.1 Обґрунтування актуальності дослідження в сфері автоматизації управління фінансами.....	29
2.2 Вибір та порівняльний аналіз методів машинного навчання для фінансових застосувань	30
2.3 Розробка методики проведення досліджень та критерії оцінки ефективності	32
2.4 Вибір інструментів та середовищ для реалізації алгоритмів	33
3 Розробка алгоритмів машинного навчання для автоматизації ведення особистих фінансів.....	36
3.1 Аналіз вимог до системи автоматизації особистих фінансів	36
3.2 Розробка алгоритмів прогнозування витрат та доходів.....	38
3.3 Реалізація алгоритмів класифікації та кластеризації фінансових транзакцій.....	42
3.4 Тестування та оцінка результатів роботи алгоритмів	45

4 Розробка алгоритмів машинного навчання для торгівлі на фінансових ринках	49
4.1 Особливості застосування машинного навчання у торгівлі	49
4.2 Розробка алгоритмів прогнозування цінових рухів	50
4.3 Створення моделей для автоматизованої торгівлі.....	54
4.4 Валідація та оптимізація торгових алгоритмів	58
5 Узагальнення результатів та перспективи розвитку	64
5.1 Аналіз отриманих результатів та їх порівняння з існуючими рішеннями	64
5.2 Рекомендації щодо впровадження розроблених алгоритмів	66
5.3 Перспективи подальших досліджень у даному напрямку	68
Висновки	70
Перелік джерел посилання	72
Додаток А Програмний код алгоритмів прогнозування витрат та доходів із застосуванням методу машинного навчання (RandomForestRegressor)	77
Додаток Б Програмний код реалізації алгоритмів класифікації та кластеризації фінансових транзакцій	80
Додаток В Програмний код тестування та оцінку результатів роботи розроблених алгоритмів	84
Додаток Г Програмний код алгоритму прогнозування цінових рухів на фінансових ринках за допомогою рекурентної нейронної мережі LSTM ..	88
Додаток Д Програмний код створення моделі для автоматизованої торгівлі за допомогою підсиленого навчання.....	90
Додаток Е Програмний код процесу валідації та оптимізації торгових алгоритмів	92
Додаток А Відомість кваліфікаційної роботи	95

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

АТС – алгоритмічні торгові системи;

ШІ – штучний інтелект;

AI – Artificial Intelligence – штучний інтелект;

API – Application Programming Interface – інтерфейс прикладного програмування;

CNN – Convolutional Neural Network – згортова нейронна мережа;

CRM-системами – Customer Relationship Management systems – системи управління відносинами з клієнтами;

CSV-файл – Comma Separated Values file – файл значень, розділених комами;

DBSCAN – Density-Based Spatial Clustering of Applications with Noise – просторове кластерування за щільністю застосунків з шумом;

DQN – Deep Q-Networks – глибока Q-мережа;

GDPR – General Data Protection Regulation – загальний регламент про захист даних;

GPU – Graphics Processing Unit – графічний процесор;

GRU – Gated Recurrent Unit – блокований рекурентний юніт;

LSTM – Long Short-Term Memory – довга короткочасна пам'ять;

MAE – Mean Absolute Error – середня абсолютна похибка;

MSE – Mean Squared Error – середньоквадратична помилка;

NLP – Natural Language Processing – обробка природної мови;

PCA – Principal Component Analysis – аналіз головних компонент;

PPO – Proximal Policy Optimization – проксимальна оптимізація політики;

PR-AUC – Precision-Recall Area Under the Curve – площа під кривою «точність-повнота»;

R^2 – R-squared – R-квадрат (коефіцієнт детермінації);

RMSE – Root Mean Squared Error – середньоквадратичне відхилення;

RNN – Recurrent Neural Network – рекурентна нейронна мережа;

ROC-AUC – Receiver Operating Characteristic Area Under the Curve –
площа під кривою операційної характеристики приймача;

SVM – Support Vector Machine – машина опорних векторів;

TF-IDF – Term Frequency-Inverse Document Frequency – частота
терміна – обернена частота документа;

t-SNE – t-distributed Stochastic Neighbor Embedding – t-розподілене
стохастичне вкладення сусідів.

ВСТУП

Сучасний фінансовий ринок характеризується високою динамікою та складністю, що обумовлює необхідність впровадження інноваційних підходів.

Управління особистими фінансами є надзвичайно важливим аспектом сучасного життя, оскільки воно закладає фундамент для фінансової безпеки та незалежності. Грамотне планування доходів і витрат, створення заощаджень та інвестицій дозволяє не тільки досягати поставлених фінансових цілей, таких як купівля житла чи автомобіля, забезпечення гідної освіти або пенсії, але й формувати «подушку безпеки» на випадок непередбачених обставин, наприклад, втрати роботи чи раптових витрат на лікування. Ефективне управління власними коштами допомагає уникнути боргів, зменшити фінансовий стрес, приймати обґрунтовані рішення щодо грошей та, зрештою, покращити загальну якість життя та досягти фінансового благополуччя.

Ефективна торгівля на фінансових ринках відіграє ключову роль як для окремих учасників, так і для економіки в цілому. Для інвесторів та трейдерів, вміння ефективно торгувати відкриває можливості для отримання прибутку, диверсифікації активів та управління фінансовими ризиками. Це передбачає глибокий аналіз ринкових тенденцій, розуміння фінансових інструментів та розробку виважених торгових стратегій, що дозволяє оперативно реагувати на зміни кон'юнктури та мінімізувати потенційні збитки. На макроекономічному рівні, ефективна торгівля сприяє підвищенню ліквідності ринків, забезпечує більш точне ціноутворення на активи та сприяє ефективному розподілу капіталу в економіці, що, стимулює економічне зростання та фінансову стабільність.

Зростання обсягів даних, доступність високопродуктивних обчислювальних ресурсів та розвиток алгоритмічних методів створюють передумови для використання машинного навчання як інструменту

автоматизації та оптимізації фінансових процесів. У зв'язку з цим, проблема розробки ефективних алгоритмів машинного навчання для автоматизації ведення особистих фінансів та торгівлі на фінансових ринках набуває особливої актуальності.

Оцінка сучасного стану проблеми. Управління особистими фінансами традиційно вимагає значних зусиль та часу, що пов'язані з аналізом доходів, витрат, планування бюджету та інвестицій. Зростання складності фінансових інструментів та зростаючий обсяг фінансових даних ускладнюють процес прийняття рішень. Одночасно, фінансові ринки стають дедалі більш конкурентними, де ефективність торгівлі часто визначається швидкістю та точністю аналізу ринкової інформації.

Машинне навчання, як галузь штучного інтелекту, пропонує широкий спектр методів для автоматизації аналізу даних, прогнозування фінансових показників та оптимізації інвестиційних стратегій. В останні роки спостерігається активний розвиток фінтех-сектору, де машинне навчання застосовується для створення персоналізованих фінансових послуг, управління ризиками, виявлення шахрайства та автоматизованої торгівлі.

Проте, незважаючи на значні досягнення, існують певні виклики, пов'язані з застосуванням машинного навчання у фінансовій сфері. Це включає питання якості та доступності даних, вибору адекватних моделей, забезпечення їхньої інтерпретованості та надійності, а також адаптації до змінних умов ринку.

Актуальність роботи та підстави для її виконання. Автоматизація управління особистими фінансами та торгівлі на фінансових ринках за допомогою алгоритмів машинного навчання має велике значення в умовах сучасної економіки. Персоналізовані фінансові поради, оптимізація інвестиційного портфеля, автоматизовані торгові системи – усе це сприяє підвищенню фінансової грамотності населення, зменшенню ризиків та збільшенню доходності інвестицій.

Підставою для виконання цієї роботи є необхідність інтеграції сучасних технологій машинного навчання в фінансові практики, що дозволить створити інструменти, здатні ефективно управляти особистими фінансами та здійснювати торгівлю на фінансових ринках з мінімальними витратами часу та ресурсів.

Крім того, розвиток таких алгоритмів сприятиме підвищенню стабільності фінансових ринків та зменшенню волатильності через більш точне прогнозування та швидку реакцію на зміни ринкових умов.

Супровідні нотатки. Історично розвиток фінансових технологій пройшов через кілька етапів, від ручного обліку та управління до автоматизованих систем на базі програмного забезпечення. З появою великих даних та розвитком обчислювальних потужностей, машинне навчання стало ключовим інструментом для аналізу складних фінансових процесів.

Перші спроби застосування машинного навчання у фінансах включали використання базових алгоритмів для прогнозування цін на акції та управління портфелем. З часом, з розвитком глибокого навчання та підсилювачів, алгоритми стали більш складними та здатними до обробки великих обсягів даних у реальному часі. Це дозволило створювати більш точні та адаптивні системи, здатні до самонавчання та автоматичного вдосконалення своїх моделей на основі нових даних.

Алгоритмізація процесів біржової торгівлі впливає на фінансові ринки, знижуючи вплив людського фактора [1, с. 37].

Проте, незважаючи на значні успіхи, досі існують обмеження, пов'язані з інтерпретованістю моделей, етикою використання даних та забезпеченням безпеки фінансових систем. Ці питання залишаються предметом активних досліджень та розробок, що підкреслює важливість подальшого вивчення та вдосконалення алгоритмів машинного навчання у фінансовій сфері.

Можливі сфери застосування результатів роботи включають персональні фінансові додатки для управління бюджетом та інвестиціями; автоматизовані торгові системи для біржових операцій; фінансові консультаційні сервіси, що надають рекомендації на основі аналізу даних; платформи для управління ризиками та оптимізації фінансових стратегій.

Апробація. Основні положення та висновки досліджень викладені на Міжнародній науковій конференції «Штучний інтелект у науці та освіті» (AISE 2024), що відбулася 1–2 березня 2024 року, XVII Міжнародній науково-практичній конференції «Інформаційні технології та автоматизація – 2024», що відбулася 31 жовтня – 1 листопада 2024 року, XII Міжнародній науково-практичній конференції «Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій», що відбулася 10–12 грудня 2024 року, 29-ому Міжнародному молодіжному форумі «Радіоелектроніка та молодь у XXI столітті», що відбувся 16–19 квітня 2025 року, та надруковані у відповідних збірниках.

Таким чином, дана кваліфікаційна робота спрямована на вирішення актуальної проблеми автоматизації фінансових процесів за допомогою сучасних технологій машинного навчання, що має важливе практичне значення та наукову новизну.

1 ТЕОРЕТИЧНІ ТА МЕТОДОЛОГІЧНІ ОСНОВИ МАШИННОГО НАВЧАННЯ У ФІНАНСОВІЙ СФЕРІ

1.1 Сучасний стан проблеми автоматизації особистих фінансів та торгівлі на фінансових ринках

У сучасних умовах стрімкого розвитку інформаційних технологій автоматизація особистих фінансів та торгівлі на фінансових ринках стає все більш актуальною і необхідною. Збільшення обсягів фінансових даних, доступність інтернету та розвиток мобільних додатків створюють передумови для впровадження інноваційних рішень, спрямованих на оптимізацію управління особистими фінансами та підвищення ефективності торгівельних операцій.

Існують різні типи алгоритмів торгівлі на фондовому ринку, включаючи програми, які намагаються зменшити витрати на здійснення угод або намагаються отримати прибуток шляхом арбітражного розгляду розбіжностей цін на різних біржах [2, с.12].

Автоматизація особистих фінансів включає використання програмного забезпечення для планування бюджету, відстеження витрат, аналізу фінансового стану та прийняття рішень щодо інвестування. Сучасні додатки, такі як Mint, YNAB (You Need A Budget) та інші, пропонують користувачам зручні інструменти для управління фінансами, але часто обмежуються базовими функціями без глибокого аналізу даних та персоналізованих рекомендацій. Використання алгоритмів машинного навчання може суттєво підвищити рівень автоматизації, дозволяючи створювати більш точні прогнози витрат, оптимізувати інвестиційні стратегії та надавати індивідуальні поради на основі аналізу великих обсягів даних.

Торгівля на фінансових ринках також активно інтегрує автоматизацію через алгоритмічні торгові системи (АТС), які здатні здійснювати операції

з високою швидкістю та точністю, мінімізуючи людський фактор та емоційні рішення. Використання машинного навчання у торгівлі дозволяє розробляти складні моделі прогнозування цінових рухів, виявляти патерни в ринкових даних та автоматично коригувати торгові стратегії відповідно до змінних умов ринку.

Показано, що використання алгоритмів у біржовій торгівлі підвищує ефективність і збільшує обсяг торгівлі [3, с. 295].

Проте, незважаючи на значні досягнення, існують виклики, пов'язані з якістю даних, ризиками перенавчання моделей, адаптивністю алгоритмів до нестабільних ринкових умов та забезпеченням їхньої прозорості та інтерпретованості.

Стан досліджень у цій галузі демонструє активний розвиток як з боку академічних інститутів, так і з боку приватного сектору. Численні наукові праці присвячені розробці та вдосконаленню алгоритмів машинного навчання для фінансових застосувань, включаючи класифікацію транзакцій, прогнозування фінансових показників, управління ризиками та створення автоматизованих торгових стратегій. Проте, багато з цих досліджень ще знаходяться на етапі експериментальної перевірки та потребують подальшої валідації в реальних умовах ринку.

Виклики автоматизації включають забезпечення високої точності та надійності моделей, інтеграцію різнорідних джерел даних, захист конфіденційної інформації користувачів, а також відповідність нормативним вимогам та етичним стандартам. Крім того, розвиток технологій машинного навчання вимагає постійного оновлення знань та адаптації до нових тенденцій на фінансових ринках, що створює додаткові перешкоди для ефективної реалізації автоматизованих систем.

Отже, сучасний стан проблеми автоматизації особистих фінансів та торгівлі на фінансових ринках характеризується активним розвитком технологій та зростаючим інтересом з боку різних учасників ринку. Водночас, існують суттєві виклики, які потребують комплексного підходу

та подальших досліджень для створення ефективних та надійних рішень у цій сфері.

1.2 Огляд алгоритмів машинного навчання в аналізі фінансових даних

Машинне навчання стало невід'ємною частиною сучасного аналізу фінансових даних, надаючи потужні інструменти для прогнозування, класифікації та оптимізації фінансових процесів. Різноманітність алгоритмів машинного навчання дозволяє ефективно вирішувати широкий спектр завдань у фінансовій сфері, від управління ризиками до автоматизованої торгівлі. У цьому розділі розглянемо основні категорії алгоритмів машинного навчання та їх застосування в аналізі фінансових даних.

Розширення алгоритмічної торгівлі стало можливим завдяки появі нових інструментів та технологій, таких як прямий доступ до ринку (Direct Market Access, DMA), який дозволяв трейдерам безпосередньо підключатись до торгових систем біржі [4, с. 225].

Алгоритми машинного навчання можна класифікувати за різними критеріями, включаючи тип навчання (супервізоване, несупервізоване, підкріплювальне), мету (класифікація, регресія, кластеризація) та специфіку задачі. У фінансовій сфері найбільш часто використовуються супервізовані та несупервізовані методи.

Супервізовані алгоритми навчаються на мічених даних, де кожен приклад включає вхідні характеристики та відповідну вихідну мітку. Ці алгоритми широко застосовуються для задач прогнозування та класифікації у фінансах.

Лінійна регресія використовується для прогнозування числових значень, таких як ціни акцій, обсяги продажів або доходи компаній. Простота та інтерпретованість роблять її популярною для базових моделей.

Логістична регресія застосовується для класифікації бінарних подій, наприклад, прогнозування дефолту клієнта або успішності кредиту.

Деревовидні методи до цієї категорії належать рішення дерев (Decision Trees), випадкові ліси (Random Forest) та градієнтні бустингові методи (Gradient Boosting Machines). Вони ефективні для обробки складних, нелінійних взаємозв'язків у даних та часто використовуються для прогнозування ризиків, цінкових рухів та інших фінансових показників.

Підтримувальні векторні машини (SVM) використовуються для класифікації та регресії, особливо ефективні у високорозмірних просторах ознак. SVM можуть застосовуватись для розпізнавання фінансових аномалій або класифікації транзакцій.

Глибокі нейронні мережі (Deep Neural Networks) здатні моделювати складні залежності в даних і використовуються для прогнозування цін, аналізу настроїв ринку та інших складних задач. Несупервізовані алгоритми працюють з неміченими даними, визначаючи структуру або закономірності без попередніх знань про вихідні мітки. Вони корисні для виявлення схожих груп, аномалій та структурування даних.

Кластеризація (Cluster Analysis) – це алгоритми, такі як К-середніх (K-Means) та ієрархічна кластеризація, використовуються для сегментації клієнтів, виявлення схожих фінансових інструментів або класифікації транзакцій. Методи зниження розмірності такі як головні компоненти аналізу (PCA) або t-SNE, застосовуються для спрощення складних фінансових даних, що полегшує їх подальший аналіз та візуалізацію.

Аномалійне виявлення (Anomaly Detection) – це алгоритми, наприклад, Isolation Forest або Autoencoders, використовуються для виявлення підозрілих транзакцій, шахрайства або інших фінансових аномалій.

Підкріплювальне навчання (Reinforcement Learning) включає навчання агента через взаємодію з середовищем, отримуючи винагороди

або покарання за свої дії. У фінансах цей метод застосовується переважно для розробки автоматизованих торгових стратегій.

Q-навчання та Deep Q-Networks (DQN) використовуються для оптимізації торгових стратегій, де агент навчається максимізувати прибуток через послідовні торгові дії.

Політики градієнтних методів застосовуються для розробки складних торгових стратегій, які можуть адаптуватися до змінних ринкових умов.

Високочастотна торгівля стала можливою завдяки швидкому розвитку технологій та зростанню обчислювальної потужності [5, с. 770].

Алгоритми машинного навчання знаходять широке застосування в різних аспектах фінансової діяльності. Розглянемо основні напрямки їх використання.

Прогнозування майбутніх цінових рухів акцій, валютних пар або інших фінансових інструментів є одним з ключових напрямків застосування машинного навчання у фінансах. Алгоритми, такі як нейронні мережі, SVM та випадкові ліси, використовуються для аналізу історичних даних, технічних індикаторів та макроекономічних показників з метою прогнозування майбутніх цінових змін.

Машинного навчання алгоритми допомагають у виявленні та оцінці фінансових ризиків. Наприклад, логістична регресія та дерева рішень можуть використовуватись для прогнозування ймовірності дефолту позичальників, а методи кластеризації допомагають сегментувати клієнтів за рівнем ризику.

Алгоритмізація процесів біржової торгівлі суттєво впливає на фінансові ринки, зокрема забезпечуючи значне покращення швидкості та точності виконання торговельних операцій [6, с. 42].

Узагальнені популярні алгоритми машинного навчання, які застосовуються в аналізі фінансових даних, подані у таблиці 1.1.

Таблиця 1.1 – Алгоритми машинного навчання, які застосовуються в аналізі фінансових даних.

Категорія	Алгоритм	Тип ML	Застосування у фінансах
Класифікація	Logistic Regression	Supervised	Прогнозування дефолту, кредитного ризику
	Decision Tree / Random Forest	Supervised	Виявлення шахрайства, скоринг кредитів
	Support Vector Machine (SVM)	Supervised	Прогнозування ринкових рухів
	Gradient Boosting (XGBoost, etc.)	Supervised	Прогнозування прибутковості, автоматична торгівля
Регресія	Linear Regression	Supervised	Прогнозування цін, доходності
	Ridge / Lasso Regression	Supervised	Регуляризована оцінка моделей для фінансових серій
	SVR (Support Vector Regression)	Supervised	Прогноз цін акцій
	LSTM (Long Short-Term Memory)	Supervised	Прогноз часових рядів (наприклад, цін акцій)
Кластеризація	K-Means	Unsupervised	Сегментація клієнтів, класифікація активів
	Hierarchical Clustering	Unsupervised	Аналіз портфелів, поділ за ризиками

Продовження таблиці 1.1

Зниження розмірності	PCA (Principal Component Analysis)	Unsupervised	Аналіз ризиків, візуалізація фінансових даних
Аномалії	Isolation Forest	Unsupervised	Виявлення шахрайства, незвичних транзакцій
	Autoencoders	Unsupervised	Детекція аномалій у торгівлі або витратах
RL/Інше	Q-Learning, DQN	Reinforcement	Автоматична торгівля, оптимізація портфеля

Алгоритмічна торгівля використовує машинне навчання для розробки стратегій автоматичного виконання торгових операцій. Глибокі нейронні мережі та підкріплювальні алгоритми дозволяють створювати адаптивні торгові системи, здатні швидко реагувати на ринкові зміни та оптимізувати прибутковість.

Машинного навчання алгоритми, такі як Isolation Forest та Autoencoders, використовуються для виявлення аномальних транзакцій, які можуть свідчити про шахрайство. Ці алгоритми аналізують великі обсяги транзакційних даних, визначаючи підозрілі патерни та аномалії, що допомагає фінансовим установам зменшити ризики втрат.

Машинне навчання використовується для створення персоналізованих фінансових порад та рекомендацій. Алгоритми класифікації та регресії аналізують фінансові дані користувачів, їхні витрати та інвестиційні звички, надаючи індивідуальні рекомендації щодо управління бюджетом, оптимізації інвестицій та досягнення фінансових цілей.

Алгоритмізація процесів біржової торгівлі має суттєвий вплив на ліквідність фінансових ринків [7, с. 85].

Використання алгоритмів машинного навчання у фінансовій сфері має низку переваг, але також супроводжується певними обмеженнями.

Переваги:

– машинне навчання дозволяє автоматизувати складні аналізи та прийняття рішень, зменшуючи потребу в ручній роботі та підвищуючи ефективність;

– алгоритми машинне навчання можуть аналізувати великі обсяги даних та виявляти складні патерни, що підвищує точність прогнозів та рішень;

– машинне навчання моделі можуть адаптуватися до змінних умов ринку, самонавчатися на нових даних та вдосконалювати свої прогнози з часом.

Обмеження:

– ефективність машинного навчання моделей залежить від якості та кількості доступних даних. Недостатня або спотворена інформація може призвести до неточних прогнозів;

– деякі алгоритми, особливо глибокі нейронні мережі, є «чорними ящиками», що ускладнює їх інтерпретацію та довіру з боку користувачів;

– машинне навчання моделі можуть занадто точно відтворювати навчальні дані, втрачаючи здатність до узагальнення на нові дані;

– деякі алгоритми, особливо глибокі нейронні мережі, вимагають значних обчислювальних ресурсів для тренування та роботи.

1.3 Тенденції розвитку машинного навчання у фінансових технологіях

Машинне навчання в останні роки стало важливим інструментом у фінансових технологіях (фінтех), відкриваючи нові можливості для автоматизації процесів, аналізу великих обсягів даних і прийняття складних рішень. Фінансові установи та стартапи все активніше інтегрують машинне навчання у свої продукти та послуги, прагнучи підвищити ефективність і

точність фінансових операцій. У цьому розділі розглянемо основні тенденції розвитку машинного навчання у фінансових технологіях.

Технічний аналіз є одним з ключових теоретичних підходів в алгоритмізації процесів біржової торгівлі [8 с. 175].

Одна з головних тенденцій полягає в удосконаленні моделей прогнозування. Застосування глибокого навчання та ансамблевих методів дозволяє отримувати точніші прогнози щодо ринкових трендів, цінних рухів, ризиків та інших фінансових показників. Висока точність прогнозів стає можливим завдяки аналізу великих обсягів даних у реальному часі, включаючи історичні ринкові дані, новини, соціальні мережі та інші джерела.

Ці вдосконалені прогнози допомагають інвесторам та трейдерам приймати більш обґрунтовані рішення, знижуючи ризики та підвищуючи дохідність. Водночас машинне навчання забезпечує персоналізовані фінансові рекомендації для користувачів, які автоматизовано аналізують їхні витрати, доходи та фінансові цілі.

Алгоритмічна торгівля та високочастотний трейдинг є одними з основних напрямків застосування машинне навчання у фінансах. Ці технології дозволяють автоматизувати торгівельні операції та аналізувати великі обсяги ринкових даних за дуже короткий час. Машинного навчання алгоритми можуть миттєво виявляти ринкові можливості, прогнозувати ціни на активи та приймати торгові рішення швидше за людину.

Фундаментальний аналіз є одним з ключових теоретичних підходів у алгоритмізації процесів біржової торгівлі [9, с. 275].

Тенденцією останніх років є підвищення складності торгових моделей, які використовують глибокі нейронні мережі та підкріплювальне навчання. Ці моделі адаптуються до змінних ринкових умов, автоматично оновлюючи свої стратегії, що робить їх особливо цінними в умовах волатильності фінансових ринків.

Ще одна важлива тенденція – використання технології обробки природної мови (NLP) для аналізу текстових даних, таких як новини, прес-релізи, публікації в соціальних мережах, форуми та інші інформаційні джерела. Вона дозволяє фінансовим установам автоматично аналізувати настрої ринку, виявляти ключові події та новини, що можуть вплинути на ціни активів.

Ця технологія допомагає трейдерам та інвесторам отримувати більш повну картину ринку та приймати обґрунтовані рішення на основі поточних подій. Наприклад, позитивні або негативні новини про компанію можуть бути автоматично інтегровані в торгові стратегії для визначення моменту купівлі або продажу акцій.

Чат-боти та віртуальні фінансові асистенти, які використовують алгоритми машинне навчання, стають все більш поширеними у фінансових технологіях. Вони дозволяють автоматизувати процеси взаємодії з клієнтами, надаючи персоналізовані консультації, управління рахунками, підготовку фінансових звітів та навіть допомогу в інвестиціях.

Завдяки обробці природної мови та машинному навчанні, ці асистенти можуть аналізувати індивідуальні фінансові дані користувачів, пропонувати поради з бюджетування та інвестицій, а також допомагати з економією коштів. Ця тенденція спрямована на покращення обслуговування клієнтів та зниження витрат на підтримку.

Машинне навчання стає важливим інструментом для виявлення шахрайства та управління фінансовими ризиками. Алгоритми виявлення аномалій дозволяють аналізувати великі обсяги транзакційних даних, виявляючи підозрілі патерни, що можуть свідчити про шахрайські дії. Машинне навчання також використовується для автоматизації процесів оцінки кредитних ризиків, прогнозування ймовірності дефолту та аналізу ризиків в інвестиціях.

Важливим напрямком є розробка більш точних моделей для запобігання шахрайству, з використанням глибоких нейронних мереж та

інших передових методів, що дозволяють виявляти складні схеми шахрайства, які не можна виявити традиційними методами.

Теорія портфелю є важливим теоретичним підходом у алгоритмізації процесів біржової торгівлі [10, с. 2].

Останнім часом все більше уваги приділяється інтеграції блокчейн-технологій та машинне навчання для забезпечення прозорості та надійності фінансових операцій. Блокчейн забезпечує децентралізований обмін фінансовою інформацією, що знижує ризики шахрайства, тоді як машинне навчання допомагає аналізувати ці дані для поліпшення управління ризиками та підвищення ефективності фінансових процесів.

Машинне навчання може бути використане для прогнозування коливань криптовалют, створення інтелектуальних контрактів та забезпечення автоматизації процесів в екосистемах блокчейну.

Остання тенденція – це зростаюче використання великих даних у поєднанні з машинним навчанням. Фінансові інституції активно збирають дані з різних джерел, таких як транзакції, соціальні мережі, демографічні дані та макроекономічні індикатори. Машинне навчання дозволяє аналізувати ці дані в реальному часі для створення прогнозів, виявлення трендів та підвищення ефективності фінансових рішень.

Завдяки інтеграції великих даних, фінансові установи можуть краще розуміти поведінку клієнтів, адаптувати свої продукти до потреб ринку та підвищувати свою конкурентоспроможність.

З розвитком машинне навчання у фінансах також виникають питання етики та регулювання. Використання машинне навчання для прийняття фінансових рішень вимагає забезпечення прозорості та інтерпретованості моделей, а також дотримання норм захисту даних. Зростає потреба в розробці моделей, які не тільки точні, але й прозорі для користувачів та регуляторів.

Крім того, важливим є питання забезпечення справедливості машинне навчання моделей, щоб уникати дискримінаційних рішень у процесах

оцінки кредитних ризиків, надання фінансових послуг та прийняття інвестиційних рішень.

1.4 Фактори, що впливають на зростаюче значення машинного навчання у фінансах

Зростаюче значення машинного навчання у фінансовому секторі обумовлене низкою факторів, які сприяють його інтеграції в різні аспекти фінансових процесів та операцій. У цьому розділі розглянемо ключові фактори, що впливають на популярність та ефективність використання машинне навчання у фінансовій сфері.

Одним з найважливіших факторів, що впливає на розвиток машинного навчання у фінансах, є стрімке зростання обсягів даних. З кожним днем фінансові установи збирають дедалі більше інформації про транзакції, клієнтів, ринкові умови, макроекономічні показники тощо. Великі дані стають основою для створення точних прогнозів, аналізу ризиків та прийняття обґрунтованих рішень.

Машинне навчання дозволяє ефективно аналізувати ці дані, знаходити закономірності та взаємозв'язки, що були б недоступні традиційним методам. Безпосередня обробка великих масивів даних стає можливою завдяки потужним алгоритмам машинного навчання, що сприяє кращій оптимізації фінансових процесів, управлінню ризиками та автоматизації прийняття рішень.

Сучасні фінансові додатки та алгоритми машинне навчання вимагають значних обчислювальних ресурсів для аналізу великих обсягів даних та навчання складних моделей. Зростаюча доступність потужних обчислювальних ресурсів, таких як хмарні обчислення (cloud computing) та графічні процесори (GPU), дозволяє здійснювати складні обчислення швидко та з меншими витратами.

Цей фактор значно знижує бар'єри для впровадження машинне навчання у фінансових установах, оскільки організації можуть використовувати доступні хмарні рішення для обробки даних без необхідності інвестувати у власну інфраструктуру. Завдяки цим технологіям фінансові установи можуть запускати масштабні обчислювальні завдання для навчання моделей машинне навчання, що робить їх доступними для ширшого кола гравців на ринку.

Машинне навчання дозволяє значно підвищити рівень автоматизації фінансових процесів, що особливо актуально у світі, де швидкість та точність прийняття рішень визначають конкурентоспроможність. Фінансові установи використовують машинне навчання для автоматизації таких завдань, як обробка транзакцій, управління ризиками, прогнозування ринкових трендів та автоматизована торгівля.

Крім того, машинне навчання дозволяє створювати автоматизовані системи персональних фінансових порад для клієнтів, які допомагають оптимізувати їхні витрати та інвестиції. Зростаюча потреба в оптимізації фінансових процесів, зменшенні витрат і покращенні обслуговування клієнтів сприяє зростанню інтересу до впровадження машинне навчання у різні сегменти фінансової індустрії.

Агентні системи є сучасним теоретичним підходом до алгоритмізації процесів біржової торгівлі [11, с. 25].

Однією з основних переваг використання машинного навчання у фінансах є здатність підвищувати точність прогнозів і оцінок ризиків. Традиційні методи аналізу даних часто не здатні враховувати складні взаємозв'язки між різними змінними або адаптуватися до швидких змін на ринку. Машинне навчання моделі, особливо глибокі нейронні мережі та інші методи прогнозування, можуть навчатися на великих обсягах даних, що дозволяє підвищити точність прогнозів щодо майбутніх ринкових рухів, ціноутворення активів та управління портфелем.

Банки та інші фінансові установи використовують машинне навчання для автоматизованого управління кредитними ризиками, що дозволяє краще оцінювати ймовірність дефолту клієнтів та знижувати втрати. Також фінансові інституції застосовують машинне навчання для оцінки ризиків у торгівлі, що допомагає трейдерам приймати більш зважені рішення в умовах мінливої ринкової кон'юнктури.

Хоча кожне з цих завдань потребує власних інструментів і методів, багато з них ключові ідеї, що лежать в їх основі, є спільними для всіх подібних проблем [12, с. 24].

Сучасні клієнти очікують персоналізованого обслуговування та швидкої реакції на їхні потреби. Машинне навчання дозволяє фінансовим установам краще розуміти поведінку своїх клієнтів, аналізуючи їхні фінансові транзакції, уподобання та звички. Це дозволяє створювати персоналізовані фінансові продукти, пропонувати індивідуальні інвестиційні стратегії та оптимізувати клієнтське обслуговування.

Фінансові асистенти, що використовують машинне навчання, здатні надавати клієнтам автоматизовані поради в режимі реального часу, допомагаючи їм краще керувати своїми фінансами. Чат-боти та віртуальні фінансові консультанти, побудовані на базі машинне навчання, дозволяють фінансовим організаціям надавати послуги 24/7, зменшуючи витрати на підтримку клієнтів та підвищуючи їхню задоволеність.

У фінансовому секторі постійно зростають вимоги до дотримання регуляторних норм та забезпечення безпеки даних. Машинне навчання стає корисним інструментом для автоматизації процесів комплаєнсу (відповідності регуляторним нормам) та запобігання шахрайству. Алгоритми виявлення аномалій дозволяють виявляти підозрілі транзакції та порушення фінансових правил у реальному часі.

Завдяки машинного навчання моделі можуть автоматично аналізувати величезні обсяги даних та швидко реагувати на загрози, що допомагає фінансовим установам забезпечувати високий рівень безпеки та відповідати

регуляторним вимогам. Крім того, технології машинне навчання допомагають автоматизувати процеси аудиту та моніторингу, що полегшує роботу фінансових установ у контексті регуляторних вимог.

У той час як теорія ймовірностей дозволяє нам робити невизначені твердження та міркувати за наявності невизначеності, теорія інформації дає нам змогу кількісно визначити кількість невизначеності в розподілі ймовірностей [13, с. 51].

Інновації у фінансових технологіях також сприяють зростанню значення машинного навчання у фінансовому секторі. Фінтех-компанії активно розробляють нові продукти та сервіси на основі машинне навчання, що спрямовані на покращення фінансової інфраструктури та обслуговування. Зокрема, це автоматизовані платформи для управління активами, кредитування на базі машинне навчання, автоматизована торгівля та інші послуги.

Фінтех-стартапи використовують машинне навчання для зниження витрат, підвищення ефективності та створення нових джерел доходу, що дозволяє їм конкурувати з традиційними фінансовими установами. Це сприяє подальшій інтеграції машинне навчання у фінансовий сектор та змушує традиційних гравців адаптувати свої підходи до обслуговування клієнтів.

1.5 Постановка задачі

Метою кваліфікаційної роботи є розроблення, аналіз та програмна реалізація моделей машинного навчання, спрямованих на покращення ефективності управління особистими фінансами та прийняття рішень при торгівлі на ринках.

У контексті стрімкого розвитку фінансових технологій та зростаючого попиту на інтелектуальні програмні системи, постає необхідність у системному дослідженні алгоритмів, здатних оперативно

обробляти великі обсяги фінансових даних та забезпечувати високий рівень точності прогнозів.

Це дозволить користувачам ефективніше управляти власними доходами й витратами, а також приймати більш обґрунтовані рішення на фондових, валютних чи криптовалютних ринках.

На нашу думку, перш ніж пробувати більш складні, необхідно зрозуміти та осягати прості методи [14, с. 26].

Задля досягнення поставленої мети в межах роботи передбачається розв'язання таких завдань: по-перше, здійснити огляд та порівняльний аналіз існуючих методів машинного навчання, які використовуються для задач фінансового прогнозування, класифікації транзакцій та виявлення аномалій; по-друге, обґрунтувати вибір підходів та інструментів, що найкраще задовольняють вимоги точності, масштабованості й швидкодії в умовах обробки різних типів фінансових даних.

По-третє, розробити і реалізувати експериментальні прототипи алгоритмів для прогнозування особистих доходів і витрат, а також для визначення торгових сигналів на фінансових ринках з урахуванням факторів ризику і волатильності.

По-четверте, провести комплексне тестування створених моделей на реальних та синтетичних наборах даних, здійснити оцінку їхньої ефективності за допомогою відповідних метрик і визначити оптимальні налаштування; нарешті, сформулювати на основі отриманих результатів практичні рекомендації щодо впровадження розроблених алгоритмів у комерційні програмні продукти, а також окреслити напрямки для подальшого розширення й поглиблення досліджень у цій сфері.

Таким чином, актуальність досліджень та розробок у галузі машинного навчання для фінансів підтверджується сучасними викликами та можливостями, які відкриває ця технологія для підвищення ефективності фінансових процесів.

2 ОБҐРУНТУВАННЯ ВИБОРУ НАПРЯМКУ ДОСЛІДЖЕННЯ ТА МЕТОДІВ РОЗВ'ЯЗАННЯ ЗАДАЧІ

2.1 Обґрунтування актуальності дослідження в сфері автоматизації управління фінансами

Актуальність дослідження в сфері автоматизації управління фінансами зумовлена стрімким розвитком цифрових технологій та необхідністю оперативної обробки й аналізу величезних обсягів даних у реальному часі. Фінансові потоки постійно ускладнюються, що вимагає від користувачів – як індивідуальних, так і корпоративних – застосування ефективних інструментів моніторингу, обліку та планування.

Завдяки автоматизованим системам стає можливим не лише значно зекономити час на рутинних операціях (наприклад, сортуванні транзакцій або підготовці звітів), а й підвищити точність прийняття рішень завдяки інтеграції алгоритмів аналізу великих масивів фінансових даних.

Зокрема, ми визначаємо машинне навчання як набір методів, які можуть автоматично виявляти шаблони в даних, а потім використовувати розкриті шаблони для прогнозування майбутнього даних або для прийняття інших рішень в умовах невизначеності (наприклад, планування того, як зберуть більше даних) [15, с. 26].

Окрім того, впровадження інноваційних методів машинного навчання сприяє більш гнучкому та персоналізованому підходу до управління фінансами. Сучасні користувачі дедалі частіше очікують на мобільні та веб-рішення, які аналізують їхні фінансові показники, надають прогнози майбутніх доходів і витрат, а також формують рекомендації щодо оптимізації витрат чи інвестування.

З точки зору бізнесу це відкриває нові можливості для розробників програмного забезпечення, банків і фінансових установ, що прагнуть підвищити привабливість своїх послуг, пропонуючи клієнтам

автоматизовані платформи обліку та аналізу витрат. Водночас на ринку зростає попит на фахівців, здатних розробляти й упроваджувати складні ML-рішення, які враховують динамічні зміни кон'юнктури фінансових ринків і поведінку користувачів.

Ще одним чинником, що підкреслює актуальність теми, є посилення конкуренції в сегменті фінансових послуг та становлення FinTech-галузі. Технологічні стартапи дедалі частіше пропонують готові інструменти для автоматизації управління коштами, щоб ефективно витіснити традиційні підходи до фінансового планування та інвестування.

Поряд з цим, питання безпеки та конфіденційності даних набуває все більшого значення, вимагаючи від авторів таких рішень глибокої експертизи у сфері криптографії, систем захисту та відповідності нормативним вимогам.

Таким чином, дослідження, присвячені використанню машинного навчання для автоматизації особистих фінансів і торгівлі на фінансових ринках, є надзвичайно актуальними та обумовленими як технічною, так і економічною доцільністю, а також перспективами подальшого розширення цифрової екосистеми фінансових послуг.

2.2 Вибір та порівняльний аналіз методів машинного навчання для фінансових застосувань

Різноманітність підходів до машинного навчання, які можуть бути застосовані у фінансовій сфері, обумовлена складністю та багатопараметричністю фінансових даних. Традиційні статистичні методи, зокрема лінійна і логістична регресія, залишаються широко вживаними для оцінки ринкових ризиків та прогнозування ключових показників, оскільки вони є відносно простими у впровадженні й забезпечують наочну інтерпретацію результатів.

Проста лінійна регресія виправдовує свою назву: це дуже простий лінійний підхід до прогнозування кількісної реакції Y на основі змінної-предиктора одинарної регресії X . Він припускає, що між X та Y існує приблизно лінійний зв'язок [16, с. 61].

Проте ці методи мають обмеження, зокрема припущення про лінійність зв'язку між ознаками та метрикою, що інколи призводить до недостатньої точності при моделюванні нестабільної чи нелінійної природи фінансових ринків. Натомість дерева рішень і їх ансамблі розширення (Random Forest, Gradient Boosting, XGBoost) дозволяють автоматично відбирати найважливіші предиктори, краще працюючи з пропущеними чи «шумними» даними, та демонструють кращу узагальнюючу здатність при прогнозуванні динаміки цін, кредитному скорингу або детекції шахрайства.

Зі зростанням обсягів і складності доступних фінансових даних все більшої популярності набувають нейронні мережі, зокрема згорткові (CNN) та рекурентні архітектури (RNN, LSTM, GRU). Вони дають змогу глибше вловлювати складні залежності в часових рядах і краще пристосовуватися до змін ринкової кон'юнктури.

Такі мережі успішно застосовують для коротко- та середньострокового прогнозування цін, виявлення патернів у даних про торговельні операції, а також для розпізнавання можливих ознак шахрайства. Утім, висока потужність глибинних моделей нерідко супроводжується проблемами перенавчання та потребує ретельної процедури підготовки вхідних даних і налаштування гіперпараметрів.

Ще один перспективний напрям – методи навчання з підкріпленням (Reinforcement Learning), які дозволяють створювати алгоритми, що самонавчаються на історичних даних та в реальному режимі, оптимізуючи стратегії торгівлі в динамічному ринковому середовищі.

Проблеми навчання з підкріпленням включають вивчення того, що робити – як зіставити ситуації з діями – щоб максимізувати числовий сигнал

винагороди. По суті, це проблеми із замкнутим циклом, оскільки дії системи навчання впливають на її пізніші вхідні дані [17, с. 16].

Вибір конкретного підходу, таким чином, визначається потребами бізнесу, доступністю даних і вимогами до швидкості та надійності прогнозів.

У багатьох випадках найбільш доцільним є комбінований підхід (ensemble learning), який дає змогу об'єднати переваги кількох методів та підвищити загальну точність і стійкість моделі.

2.3 Розробка методики проведення досліджень та критерії оцінки ефективності

Відправною точкою для розробки методики проведення досліджень є формування узгодженої послідовності кроків, що охоплюють збір та підготовку даних, вибір моделей машинного навчання, реалізацію експериментів, а також аналіз і візуалізацію отриманих результатів.

Якщо тестовий набір вважається необхідним, існує кілька методів розділення вибірок. Невипадкові підходи до розділення даних іноді є доречними [18, с. 82].

Насамперед визначаються джерела фінансової інформації: біржові та банківські API, платіжні системи, публічні звіти, аналітичні платформи. Зібрані дані проходять процедури очищення від пропущених або помилкових значень, стандартизації та нормалізації, що поліпшує стабільність і точність роботи алгоритмів.

Ера «великих даних» стала можливою завдяки розвитку технологій збору даних; практично все, що ми робимо сьогодні, включаючи купівлю товару, використання телефону чи перехід на сайт, збирається та зберігається десь [19, с. 24].

Далі здійснюється розподіл доступного набору прикладів на тренувальну, валідаційну і тестову вибірки, аби забезпечити коректну оцінку узагальнюючої здатності моделей і запобігти перенавчанню.

Після цього проводиться етап моделювання: порівняння обраних алгоритмів (лінійних, дерево-рішучих, ансамблевих, глибоких нейронних мереж тощо) в умовах єдиного дослідного середовища для однозначності висновків.

Критеріями оцінки ефективності виступають як загальноприйняті метрики, так і спеціалізовані фінансові показники. Зокрема, для регресійних задач застосовуються показники MSE, RMSE, MAE й коефіцієнт детермінації R^2 , тоді як у класифікаційних завданнях акцент робиться на точності (Accuracy), повноті (Recall), точності передбачення (Precision), F1-мірі та ROC-AUC.

Враховуючи розмір доступних вибірок, теорія машинного навчання прагне визначити ступінь точності, яку учень може очікувати на основі таких вибірок [20, с. 25].

Якщо йдеться про автоматизовану торгівлю, до уваги беруться також прибутковість (Profit), максимальна просадка (Drawdown), коефіцієнт Шарпа (Sharpe ratio) та інші показники ризику/доходності, які дають змогу зробити висновок про практичну придатність алгоритму на реальному ринку. Крім того, передбачаються додаткові методи валідації результатів, такі як крос-валідація чи тестування на більш ранніх або пізніших історичних періодах (forward testing), що дозволяє оцінити стійкість моделей до змін ринкових умов і покращити їхню здатність до узагальнення.

2.4 Вибір інструментів та середовищ для реалізації алгоритмів

Вибір інструментів та середовищ для реалізації алгоритмів машинного навчання у фінансовій сфері обумовлюється насамперед

вимогами до обробки великих обсягів даних, гнучкістю налаштування моделей та зручністю інтеграції з наявними інформаційними системами.

Найбільш популярною мовою програмування для машинного навчання та інтелектуального аналізу даних, в наш час, є Python, оскільки вона є простою у вивченні та використанні, має велике та активне співтовариство розробників, і пропонує широкий вибір бібліотек та фреймворків для машинного навчання [21, с. 32].

Мова Python, яка завдяки багатому екосистемному набору бібліотек (pandas, NumPy, scikit-learn, TensorFlow, PyTorch, XGBoost та інші) дає змогу швидко та ефективно будувати прототипи моделей, реалізовувати обробку даних та візуалізацію результатів. Універсальність Python також підкріплюється інтеграцією з хмарними платформами (Google Cloud Platform, AWS, Microsoft Azure), що дає змогу масштабувати обчислення та зберігання даних у міру зростання проєкту.

Важливою складовою є використання Jupyter Notebook, що спрощує процес розробки завдяки інтерактивним блокам коду, які можна поетапно виконувати та аналізувати безпосередньо під час дослідження.

Одним з основних питань при створенні складних програмно-технічних комплексів, до яких належать мультиагентні системи, є вибір та обґрунтування моделі життєвого циклу, починаючи з моменту прийняття рішення про необхідність його створення та закінчуючи моментом його повного вилучення з експлуатації [22, с. 621].

Окрім Python, чималий інтерес становить середовище R, особливо в аналітиків і статистиків, котрі звикли до широких можливостей побудови статистичних моделей і візуалізації (ggplot2, Shiny тощо).

Утім, з огляду на потребу швидкої інтеграції з різноманітними джерелами даних і задля забезпечення високої продуктивності, найчастіше обирають Python із його розгалуженою інфраструктурою фреймворків та інструментів.

Так, наприклад, в основі методу навчання з підкріпленням лежать ті основні принципи адаптивної поведінки, які дозволяють живим організмам пристосовуватися до змінних або невідомих умов проживання [23, с. 78].

Для більш масштабованих проєктів або тих, що вимагають паралельної обробки великих потоків даних у реальному часі, можуть бути корисними платформи на кшталт Apache Spark або Hadoop, які легко взаємодіють із мовою Scala чи бібліотеками на Python.

Також вагоме значення має відповідне оточення для розгортання готових рішень, де поширеною практикою є контейнеризація (Docker) і управління контейнерами (Kubernetes), що полегшує перенесення розроблених моделей між середовищами (від локального сервера до хмарних кластерів).

Нарешті, необхідно враховувати й наявність підтримки специфічних бібліотек або API провайдерів біржових даних та платіжних систем, де вибір платформи часто визначається мовою та протоколами, якими користуються ці сервіси.

Методи штучного інтелекту корисні для захисту від кібератак, наприклад, шляхом виявлення незвичайних моделей поведінки, але вони також сприятимуть потужності, живучості та здатності до поширення шкідливого програмного забезпечення. Наприклад, методи навчання з підкріпленням використовувалися для створення високоефективних інструментів для автоматизованих, персоналізованих шантажних та фішингових атак [24, с. 50].

У комплексі, вибір зазначених методів та інструментів забезпечує потрібний рівень гнучкості, масштабованості й точності, що дає підґрунтя для переходу до експериментальної та практичної частини роботи в наступних розділах.

3 РОЗРОБКА АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ ДЛЯ АВТОМАТИЗАЦІЇ ВЕДЕННЯ ОСОБИСТИХ ФІНАНСІВ

3.1 Аналіз вимог до системи автоматизації особистих фінансів

Аналіз вимог до системи автоматизації особистих фінансів передбачає комплексне врахування функціональних, технічних та безпекових аспектів, оскільки фінансові операції та дані про них є надзвичайно чутливою інформацією. З функціональної точки зору насамперед важливо забезпечити автоматичний збір і категоризацію транзакцій, що дасть змогу користувачеві оперативно відстежувати рух коштів, аналізувати структуру витрат та порівнювати показники доходів і витрат у динаміці.

Для цього бажаним є інтеграційний модуль з банківськими та платіжними API, який дозволяє системі в реальному часі завантажувати дані про операції, включно з інформацією про дату, суму, категорію витрат чи мерчанта. Система також повинна пропонувати ефективну візуалізацію: графіки, діаграми й аналітичні звіти, що допомагають користувачеві краще зрозуміти фінансову картину (загальні залишки, динаміка витрат, співвідношення різних категорій тощо).

В результаті інтелектуального аналізу даних може виникнути надзвичайна ситуація, при якій побудована аналітична модель не буде очевидною для аналітика [25, с. 14].

Другим важливим аспектом є потреба у прогнозуванні фінансових потоків. На основі історичних даних та використання алгоритмів машинного навчання система має формувати прогнози щодо майбутніх витрат і доходів, виявляти потенційні «діри» у бюджеті, пропонувати сценарії оптимізації фінансів (наприклад, зменшення витрат на певні категорії або підвищення обсягів заощаджень). Корисною буде функція виявлення аномалій чи нетипових транзакцій, завдяки якій можна своєчасно розпізнати шахрайські дії або помилки у розрахунках. Не менш суттєвим є

здатність системи надавати персоналізовані рекомендації, базуючись на поведінкових патернах користувачів. Це можуть бути поради щодо розміщення депозитів, інвестицій, використання кредитних ліній із вигіднішими відсотковими ставками тощо.

Результати, що сильно перекриваються, матимуть непропорційно велику вагу, якщо вважати їх рівними результатам, що не перекриваються. Водночас, міткам, пов'язаним з великою абсолютною віддачею, слід надавати більше значення, ніж міткам з незначною абсолютною віддачею [26, с. 68].

Технічні та безпекові вимоги зумовлені потребою в надійному захисті даних: шифрування під час передачі й зберігання інформації, дотримання стандартів конфіденційності (наприклад, GDPR у ЄС чи відповідні локальні регуляції). Система має забезпечувати масштабованість, адже при збільшенні кількості користувачів чи транзакцій завжди залишається потреба у швидкому відгуку та відсутності затримок. Резервування та регулярне бекапування інформації є критично важливими для запобігання втратам даних. Окрім цього, необхідно передбачити зручність розгортання системи, можливість інтеграції з існуючими обліковими та CRM-системами, а також підтримку мобільних застосунків чи веб-інтерфейсів для підвищення доступності. Важливим фактором, що сприяє ширшому впровадженню подібних рішень, є наявність користувацького інтерфейсу з інтуїтивною навігацією та можливістю швидкого внесення правок у категорії або бюджетні плани. Водночас система має забезпечувати гнучку настройку прав доступу: різним користувачам можуть бути надані різні ролі, що визначають, хто саме може лише переглядати дані, а хто – вносити зміни. Синергія вищезазначених складових формує цілісну картину вимог до системи автоматизації особистих фінансів та окреслює технічний і функціональний фундамент для подальшої розробки алгоритмів машинного навчання, спрямованих на персоналізовану аналітику і прогнозування.

3.2 Розробка алгоритмів прогнозування витрат та доходів

Розробка алгоритмів прогнозування витрат і доходів у системах автоматизації особистих фінансів базується передусім на якісно сформованих вхідних даних та правильно дібраній моделі машинного навчання. На початковому етапі необхідно зібрати історичну інформацію про транзакції користувача, що може охоплювати дані за декілька попередніх місяців або років, залежно від доступності та бажаної глибини аналізу. Така інформація зазвичай містить дати й суми операцій, категорії витрат (продукти харчування, транспорт, комунальні послуги, розваги тощо) або джерела надходження доходів (заробітна плата, бонуси, роялті, дивіденди). Окрім категоризації на основі визначених типів, доцільно враховувати також додаткові чинники: сезонність (наприклад, передноворічні витрати) чи залежність від певних календарних циклів (зарплата двічі на місяць, щоквартальні премії).

Наступним кроком є попередня обробка та вибір релевантних ознак. Зокрема, частину змінних можна сконструювати самостійно (feature engineering): наприклад, порівняння витрат із середнім рівнем доходів за певний період чи виокремлення сезонних компонент, що суттєво впливають на витрати. Корисно також проаналізувати кореляції між різними категоріями та динамікою доходів, що допоможе сформувати чіткішу картину поведінки користувача. На цьому ж етапі важливо подбати про обробку пропущених чи некоректних даних та привести числові показники до належного масштабу (нормалізація або стандартизація), щоб запобігти домінуванню великих чисел над меншими.

Алгоритмічна стратегія торгівлі подає ринкові дані (історичні або поточні) в комп'ютер (для бек-тестування або автоматичного виконання). Програма потім надсилає ордери брокеру через API та отримує зворотні сповіщення про статус ордерів від брокера [27, с. 14].

Для безпосереднього прогнозування можуть застосовуватися різноманітні алгоритми регресії, залежно від складності та обсягу даних. Зокрема, лінійна регресія залишається зрозумілим та інтерпретованим варіантом, однак для обліку нелінійних залежностей і випадків зі «шумними» даними більш ефективними виявляються моделі на основі дерев рішень (Random Forest, XGBoost), які краще працюють з різнотипними та пропущеними ознаками, автоматично відбирають найбільш інформативні предиктори і здатні утримувати прийнятну точність навіть за відсутності деяких змінних. У разі більшого набору даних, особливо коли існують виражені часові закономірності, можуть застосовуватись рекурентні нейронні мережі (LSTM, GRU), здатні виявляти довгострокові залежності у фінансових рядах.

Python має автоматизоване збирання сміття, що дозволяє програмісту позбутися необхідності керувати пам'яттю [28, с. 24].

Обрані моделі навчають на тренувальній вибірці, де кожне спостереження містить загальний набір ознак (часова мітка, категорії, історичні показники витрат і доходів, а також додаткові фактори), а цільовою змінною є відповідна сума витрат чи доходів у певному періоді (день, тиждень, місяць). Після навчання алгоритму його валідують на відкладеній вибірці, порівнюючи прогнозовані значення з фактичними за допомогою метрик (MSE, RMSE, MAE, R^2). На цьому етапі нерідко виявляються недоліки у виборі моделі чи ознак: наприклад, виявляється, що деякі категорії з'являються занадто рідко або що існує тренд на зростання витрат у вихідні, який потребує окремого опрацювання. Отримані результати аналізуються, при потребі вносяться корективи у вибір алгоритму чи процес формування ознак.

Завдання прогнозування фінансових часових рядів є надзвичайно складними, головним чином через високий рівень шуму та загальноприйняту напівсильну форму ринкової ефективності [29, с. 1].

Схема алгоритму прогнозування витрат та доходів із застосуванням методу машинного навчання (RandomForestRegressor), поданий на рисунку 3.1.

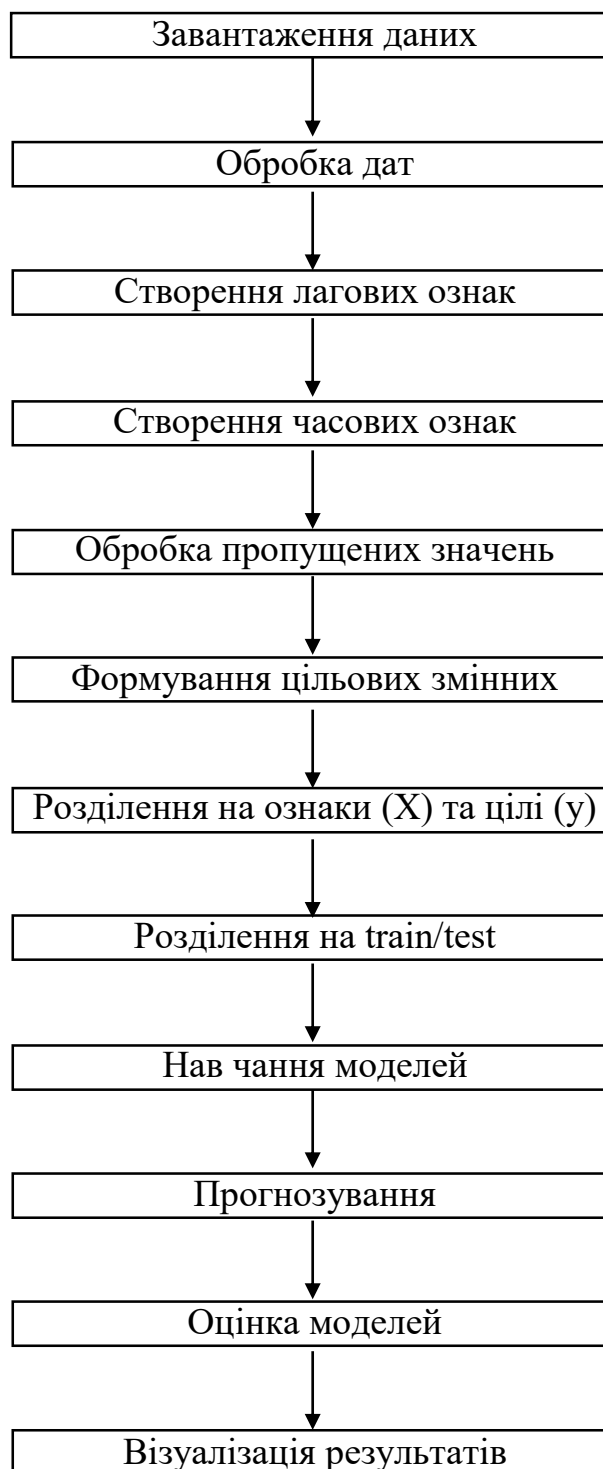


Рисунок 3.1 – Схема алгоритму прогнозування витрат та доходів із застосуванням методу машинного навчання (RandomForestRegressor)

На заключному етапі реалізується інтеграція прогнозованої моделі у прикладну систему. Користувач, отримуючи рекомендації щодо майбутніх витрат або попередження про можливі бюджетні розриви, може вчасно скоригувати власну фінансову стратегію чи звернути увагу на певні категорії, в яких витрати виходять за межі звичного рівня. В окремих випадках модель може працювати у режимі реального часу (наприклад, при кожному надходженні нових транзакцій), проте частіше передбачено періодичний перерахунок (раз на день чи тиждень), щоб знизити навантаження на систему. Зрештою, основна мета полягає у наданні користувачеві зручного інструменту, який не лише формує наочну статистику минулих операцій, а й допомагає передбачити майбутні фінансові тенденції, щоб більш усвідомлено планувати бюджет та ухвалювати економічно вигідні рішення.

Програмний код алгоритмів прогнозування витрат та доходів із застосуванням методу машинного навчання (`RandomForestRegressor`), поданий у додатку А.

Даний код на мові програмування Python демонструє розробку алгоритмів прогнозування витрат та доходів із застосуванням методу машинного навчання (`RandomForestRegressor`).

Дані завантажуються з CSV-файлу, проводиться попередня обробка (створення часових ознак та лагових характеристик), далі дані розбиваються на тренувальну та тестову вибірки, після чого тренуються дві моделі для прогнозування наступного значення витрат та доходів. Результати оцінюються за допомогою метрик MSE, MAE та R^2 , а також здійснюється візуалізація реальних і прогнозованих значень.

Цей приклад можна адаптувати під конкретні потреби, додаючи додаткове `feature engineering`, використовуючи інші алгоритми або застосовуючи методи глибокого навчання для роботи з часовими рядами.

3.3 Реалізація алгоритмів класифікації та кластеризації фінансових транзакцій

Реалізація алгоритмів класифікації та кластеризації фінансових транзакцій є одним із ключових компонентів автоматизованої системи особистих фінансів, оскільки дає змогу систематизувати велику кількість даних та робити на їхній основі корисні висновки. Зокрема, класифікація транзакцій передбачає визначення категорій (наприклад, «Продукти харчування», «Комунальні послуги», «Транспорт», «Розваги» чи «Кредитні платежі»), до яких належить конкретна операція на підставі інформації про дату, суму, одержувача, опис призначення платежу тощо. Достеменне класифікування дозволяє користувачам швидко отримувати зведені дані про розподіл витрат у різних категоріях і помічає нетипові випадки, які можуть свідчити про потенційне шахрайство або необхідність уточнення.

Для виконання задачі класифікації застосовують широкий спектр алгоритмів машинного навчання. Класичним та водночас ефективним інструментом є дерева рішень або їхні ансамблеві модифікації (Random Forest, Gradient Boosting, XGBoost), які добре працюють з різнотипними та пропущеними даними й автоматично відбирають найважливіші предиктори. Якщо опис транзакції містить текстову інформацію (скажімо, призначення платежу чи назву мерчанта), додатково можуть застосовуватися підходи з NLP (наприклад, векторизація тексту за допомогою TF-IDF або word embeddings). Серед інших популярних методів вирізняють логістичну регресію, зручну для інтерпретації, а також нейронні мережі, які у поєднанні з репрезентацією текстів часто демонструють високу точність. Основними метриками успіху слугують точність (Accuracy), Precision, Recall та F1-score, а якщо потрібно визначити ефективність виявлення нетипових або шахрайських транзакцій, до уваги беруть і метрики ROC-AUC чи PR-AUC.

Кластеризація, на відміну від класифікації, не потребує наявності заздалегідь визначених міток. Вона корисна для згрупування транзакцій або

користувачів за схожими патернами витрат. Наприклад, за допомогою алгоритму k-means можна виділити сегменти, які витрачають найбільше коштів на певну категорію товарів чи послуг, або визначити групи користувачів, що здійснюють аналогічні регулярні платежі. Альтернативою слугують алгоритми ієрархічної кластеризації чи DBSCAN, які краще виявляють «шумні» точки та більш складні структури в даних. Порівняно з класифікацією кластеризація є більш гнучкою, але потребує правильної та вдумливої інтерпретації результатів, оскільки групи можуть формуватися за прихованими параметрами, які не завжди очевидні.

У процесі розробки кластеризаційних рішень важливо дотримуватися низки етапів. Спочатку потрібно належно підготувати дані: відкинути або скоригувати аномальні значення, нормалізувати числові ознаки, здійснити кодування категорій (One-Hot або Target Encoding). Далі слід обрати відповідну метрику відстані (наприклад, Евклідова, косинусна чи Манхеттенська) й визначити оптимальний набір параметрів (наприклад, кількість кластерів у k-means, радіус близькості в DBSCAN). У якості метрики оцінки якості поділу найчастіше застосовують коефіцієнт силуету (Silhouette Score) або індекси типу Calinski-Harabasz. Важливо переконатися, що знайдені кластери мають зрозумілий зміст, аби їх можна було використовувати для побудови персоналізованих рекомендацій чи оперативного виявлення незвичних транзакцій.

Інтеграція цих алгоритмів у кінцевий програмний продукт передбачає щоденну або періодичну обробку нових фінансових записів, актуалізацію моделей і перевірку їхньої продуктивності. З практичного погляду, наявність обох підходів (класифікації та кластеризації) дає змогу сформувати повну картину транзакційної активності: з одного боку, система автоматично визначає конкретні категорії для кожної операції, з іншого – визначає приховані патерни й сегменти користувачів. Це є передумовою для якісних аналітичних звітів, вчасних попереджень про надмірні витрати та, зрештою, створення оптимізованих індивідуальних фінансових стратегій.

Схема алгоритму класифікації та кластеризації фінансових транзакцій, поданий на рисунку 3.2.

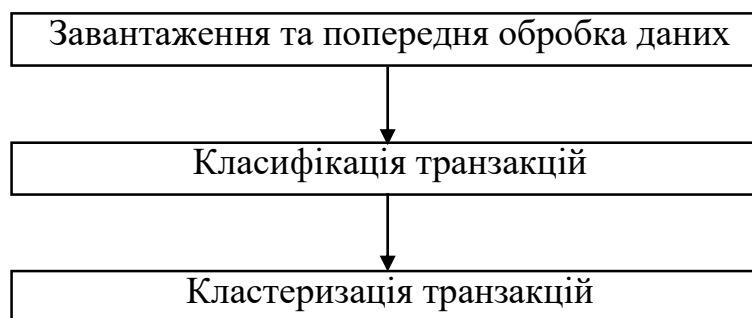


Рисунок 3.2 – Схема алгоритму класифікації та кластеризації фінансових транзакцій

Програмний код реалізації алгоритмів класифікації та кластеризації фінансових транзакцій, поданий у додатку Б.

Даний код на мові програмування Python демонструє реалізацію алгоритмів класифікації та кластеризації фінансових транзакцій.

Дані завантажуються з CSV-файлу, який містить інформацію про транзакції (наприклад, ідентифікатор транзакції, дату, суму, опис та категорію). Спочатку виконується класифікація транзакцій за категоріями на основі текстового опису та числової ознаки «сума», після чого проводиться кластеризація для виявлення прихованих груп транзакцій.

Текстовий опис транзакцій перетворюється у вектори за допомогою TfidfVectorizer. Числова ознака «amount» обробляється окремо та об'єднується з TF-IDF ознаками за допомогою функції hstack. Модель RandomForestClassifier навчається на комбінованих ознаках, після чого проводиться оцінка її точності. Для кластеризації використовується новий TfidfVectorizer для перетворення описів транзакцій.

Об'єднання текстових ознак з числовою ознакою «amount» дозволяє сформувати простір ознак для KMeans. За допомогою TruncatedSVD дані зменшуються до 2 вимірів для візуалізації кластерів, які відображаються на

графіку. Цей код можна адаптувати під конкретний набір даних або змінити параметри алгоритмів для досягнення кращих результатів.

3.4 Тестування та оцінка результатів роботи алгоритмів

Після розробки алгоритмів, що забезпечують автоматизацію ведення особистих фінансів, надзвичайно важливим етапом є їх комплексне тестування та оцінка результатів роботи. На першому етапі проводиться внутрішнє тестування моделей на підготовлених наборах даних, де дані розподіляються на тренувальну, валідаційну та тестову вибірки. Використання крос-валідації дозволяє мінімізувати ризик перенавчання та оцінити здатність алгоритмів узагальнювати інформацію на нових даних. Під час цього етапу застосовуються стандартні метрики оцінки, такі як середньоквадратична помилка (MSE), середня абсолютна помилка (MAE), кореляційний коефіцієнт детермінації (R^2) для регресійних задач, а також точність (Accuracy), Precision, Recall, F1-score та ROC-AUC для класифікаційних завдань. Для алгоритмів, спрямованих на кластеризацію, використовують коефіцієнт силуету та інші індекси, що дозволяють визначити якість розподілу даних у групи.

MSE (Mean Squared Error) – середньоквадратична помилка. Це середній квадрат різниці між реальними значеннями і передбаченими. Перевага: сильно штрафує великі помилки. Недолік: важко інтерпретувати через квадрат одиниці виміру.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.1)$$

де n – кількість одиниць спостереження;

y_i – значення, що спостерігаються;

\hat{y}_i – передбачені значення.

MAE (Mean Absolute Error) – середня абсолютна помилка. Це середнє абсолютне відхилення між передбаченням і фактичними значеннями. Перевага: менш чутлива до викидів, ніж MSE. Недолік: менш чутлива до великих помилок.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - x| \quad (3.2)$$

де n – кількість підібраних точок;

x_i – це прогноз;

x – це фактичне значення.

R^2 (коефіцієнт детермінації). Означає: яка частка варіації залежної змінної пояснюється моделлю.

$$R^2 = 1 - \frac{V(y|x)}{V(y)} = 1 - \frac{\sigma^2}{\sigma_y^2} \quad (3.3)$$

де σ^2 – дисперсія випадкової величини y ;

σ_y^2 – умовна дисперсія залежної змінної (дисперсія похибки моделі).

$R^2 = 1$ – ідеальне передбачення; $R^2 = 0$ – модель не краща за просто середнє. Може бути < 0 , якщо модель гірша за середнє.

Наступним кроком є проведення тестування моделей на історичних даних з метою здійснення *backtesting*, що дозволяє відтворити поведінку системи у минулих ринкових умовах та оцінити її здатність прогнозувати майбутні тенденції.

Такий підхід дозволяє не лише перевірити точність прогнозів, але й визначити стійкість алгоритмів до змін ринкових умов, сезонності та аномальних даних. Крім того, в умовах реального часу проводиться *forward testing* (*paper trading*), що дозволяє оцінити ефективність алгоритмів в умовах без фактичного ризику для користувача, забезпечуючи можливість оперативного реагування на змінні ринкові сценарії.

Особлива увага приділяється аналізу похибок та ідентифікації причин невідповідностей між прогнозованими та фактичними даними. За допомогою детального аналізу помилок можна виявити слабкі місця моделі, уточнити набір ознак або внести корективи у підхід до обробки даних. Окрім числових метрик, оцінка результатів роботи алгоритмів включає в себе аналіз інтерпретованості моделі – здатність системи пояснити прийняті рішення користувачу, що є важливим для довіри до автоматизованих фінансових систем.

На заключному етапі проводиться порівняння результатів роботи розроблених алгоритмів з існуючими рішеннями або базовими моделями, що дозволяє оцінити економічну доцільність та практичну ефективність запропонованих підходів. Таким чином, комплексне тестування та оцінка результатів роботи алгоритмів забезпечує надійність, стабільність та адаптивність розроблених моделей, що в подальшому сприяє їх успішній інтеграції у системи автоматизації ведення особистих фінансів та підвищенню якості прийняття рішень користувачами.

Схема алгоритму тестування та оцінку результатів роботи розроблених алгоритмів, поданий на рисунку 3.3.

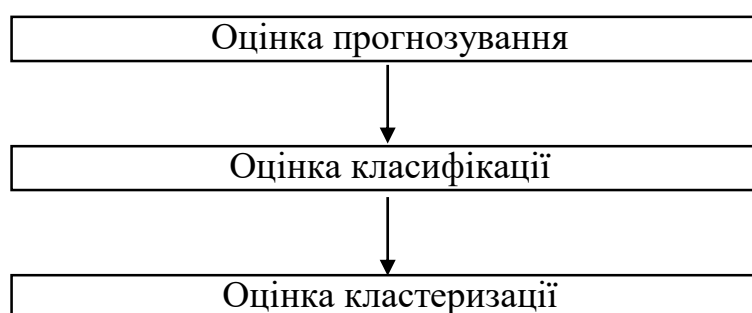


Рисунок 3.3 – Схема алгоритму тестування та оцінку результатів роботи розроблених алгоритмів

Програмний код тестування та оцінку результатів роботи розроблених алгоритмів, поданий у додатку В.

Даний код на мові програмування Python демонструє тестування та оцінку результатів роботи розроблених алгоритмів для прогнозування (регресійної задачі), класифікації та кластеризації фінансових транзакцій.

Цей код містить функції для обчислення основних метрик, побудови графіків для візуалізації результатів та приклади демонстрації з використанням як реальних (припущених, що попередньо отриманих у відповідних розділах) даних, так і створених штучних даних для демонстрації.

Функція `evaluate_forecasting` обчислює середньоквадратичну помилку (MSE), середню абсолютну помилку (MAE) та коефіцієнт детермінації (R^2) для прогнозних значень, після чого будує графік з фактичними та прогнозованими значеннями.

Функція `evaluate_classification` обчислює точність класифікації і виводить детальний звіт, що включає показники `precision`, `recall` та `F1-score` для кожного класу.

Функція `evaluate_clustering` обчислює `Silhouette Score` для отриманих кластерів і візуалізує результати на діаграмі розсіювання (передбачено, що простір ознак має 2 виміри).

Для демонстрації створюються штучні дані для кожної з задач. У реальному проєкті ці частини слід замінити на результати, отримані після навчання алгоритмів (наприклад, змінні `y_exp_test`, `y_exp_pred`, `y_test/y_pred` для класифікації, та векторизовані ознаки для кластеризації).

Цей код можна адаптувати під конкретні потреби та інтегрувати у загальну схему тестування розроблених алгоритмів для автоматизації ведення особистих фінансів.

4 РОЗРОБКА АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ ДЛЯ ТОРГІВЛІ НА ФІНАНСОВИХ РИНКАХ

4.1 Особливості застосування машинного навчання у торгівлі

Особливості застосування машинного навчання у торгівлі на фінансових ринках зумовлені високою динамічністю, непередбачуваністю та складністю ринкових даних, що характеризуються великою волатильністю, шумом та нестационарністю. Сучасні ринки генерують величезні обсяги інформації, серед якої приховані закономірності можуть бути виявлені лише за допомогою потужних алгоритмів аналізу даних. У цьому контексті машинне навчання відкриває нові можливості для прогнозування трендів, визначення оптимальних торгових сигналів і розробки адаптивних стратегій, які здатні оперативно реагувати на зміни ринкових умов.

Нині ринки деривативів досягли надзвичайного успіху. Основна причина полягає в тому, що вони приваблюють багатьох різних типів трейдерів і мають високий рівень ліквідності. Коли трейдер хоче взяти одну сторону контракту, зазвичай немає проблем із пошуком когось, хто готовий взяти іншу сторону [30, с. 35].

Однією з ключових особливостей є необхідність обробки високочастотних часових рядів, що вимагає застосування спеціалізованих методів, таких як рекурентні нейронні мережі (LSTM, GRU) або інші глибинні моделі, здатні враховувати довгострокові залежності і послідовність даних. Також важливе застосування методів підсиленого навчання, де торгові агенти самонавчаються шляхом отримання винагород і штрафів, що дозволяє створювати алгоритми, які оптимізують прийняття рішень у режимі реального часу.

Крім того, алгоритмічна торгівля вимагає надзвичайно високої швидкості обробки даних та прийняття рішень, що обумовлює необхідність

використання потужних обчислювальних ресурсів і оптимізації програмних рішень, а також створення надійної інфраструктури для реалізації високочастотних стратегій.

У цьому контексті важливе інтегрування ризик-менеджменту, де моделі машинного навчання дозволяють аналізувати й управляти ризиками, зокрема прогнозувати можливі просадки, враховувати ліквідність і коректувати стратегії в умовах різних ринкових сценаріїв. Інтеграція різних типів даних – історичних цін, обсягів торгів, технічних індикаторів, а також новинних потоків і інформації з соціальних мереж – дозволяє будувати комплексні моделі, здатні забезпечити більш точні прогнозування, забезпечення безпеки, етики та своєчасне реагування на зміни ринку.

Перспективи безпеки в штучному інтелекті охоплюють широкий спектр питань, від технічних заходів до етичних та правових норм, спрямованих на забезпечення безпечного розвитку та впровадження технологій штучному інтелекті. Основною метою є створення штучному інтелекті, який є не тільки інтелектуально потужним, але й безпечним для людей, суспільства та навколишнього середовища [31, с. 578].

Отже, застосування машинного навчання у торгівлі є складним, проте надзвичайно перспективним напрямком, що відкриває можливості для розробки інтелектуальних торгових систем з високою адаптивністю, ефективністю та здатністю працювати в умовах постійних змін.

4.2 Розробка алгоритмів прогнозування цінових рухів

У цьому підрозділі розглядається розробка алгоритмів прогнозування цінових рухів на фінансових ринках із застосуванням методів машинного навчання, що є критично важливим для формування торгових стратегій та управління ризиками. Ринкові дані характеризуються високою волатильністю, непередбачуваністю та складними нелінійними залежностями, тому традиційні статистичні підходи часто виявляються

недостатньо ефективними для аналізу такої інформації. З огляду на це, було прийнято рішення використовувати методи глибинного навчання, зокрема рекурентні нейронні мережі (LSTM), які здатні вловлювати довгострокові залежності та послідовні патерни в часових рядах.

Першим етапом розробки алгоритму є збір та попередня обробка історичних даних про ціни фінансових інструментів. Для аналізу використовуються дані про закриття цін (Close), які після завантаження з відповідного джерела (наприклад, CSV-файлу) проходять етап нормалізації із застосуванням `MinMaxScaler` для приведення значень до діапазону $[0, 1]$. Така нормалізація сприяє стабільнішому процесу навчання нейронної мережі, оскільки допомагає уникнути домінування великих числових значень.

Для того, щоб перетворити часовий ряд даних у формат, придатний для навчання рекурентної моделі, здійснюється формування послідовностей (windowing). При цьому, для кожного прогнозу використовується інформація за останні 60 днів, що дозволяє алгоритму аналізувати історичну динаміку та виявляти патерни, що можуть впливати на майбутні зміни цін. Таким чином, кожне спостереження представлено у вигляді послідовності з 60 числових значень, а цільова змінна – це значення ціни, яке наступне після сформованої послідовності.

Побудова моделі базується на архітектурі LSTM, що складається з двох послідовних шарів. Перший LSTM-шар із зазначенням параметра `return_sequences=True` дозволяє зберегти послідовність вхідних даних для наступного шару, а використання `Dropout` сприяє запобіганню перенавчанню, що є важливим з огляду на шумність ринкових даних. Другий LSTM-шар обробляє отриману інформацію без повернення послідовності, після чого її результат подається у повнозв'язний шар (`Dense`) для отримання фінального прогнозу. Модель компілюється з використанням оптимізатора `Adam` та функції втрат `mean_squared_error`, що

дозволяє мінімізувати різницю між прогнозованими та фактичними значеннями цін.

Навчання моделі проводиться на тренувальній вибірці, що складає близько 80 % від загального обсягу даних, при цьому решта даних використовується для тестування моделі. Такий підхід дозволяє здійснити *backtesting*, тобто відтворити історичну поведінку ринку та оцінити ефективність алгоритму на реальних даних. Оцінка якості моделі здійснюється за допомогою метрик, таких як середньоквадратична помилка (MSE), середня абсолютна помилка (MAE) та коефіцієнт детермінації (R^2). Отримані результати дозволяють визначити точність прогнозування та ступінь узагальнення моделі.

Після навчання та тестування моделі було проведено аналіз її роботи. Результати показали, що алгоритм здатний адекватно прогнозувати загальні тренди в динаміці цін, що є важливим для формування торгових сигналів та розробки стратегій управління капіталом. Проте, модель може мати труднощі з прогнозуванням короткострокових коливань, що обумовлено високою волатильністю ринку. Для покращення точності прогнозування рекомендовано розширити набір ознак шляхом включення додаткових індикаторів, таких як обсяги торгів, технічні індикатори (наприклад, RSI, MACD) та інша інформація, що відображає ринкову кон'юнктуру.

Таким чином, розробка алгоритмів прогнозування цінових рухів із застосуванням LSTM демонструє ефективність використання методів глибинного навчання для аналізу складних часових рядів. Отримані результати можуть бути використані як основа для подальшої розробки алгоритмічних торгових стратегій, що дозволяють приймати більш обґрунтовані рішення в умовах ринкової невизначеності. Розроблена методика має потенціал для інтеграції у більш комплексні системи автоматизованої торгівлі, де прогнозування цінових рухів є важливою складовою управління ризиками та оптимізації торгових операцій.

Схема алгоритму прогнозування цінових рухів на фінансових ринках за допомогою рекурентної нейронної мережі LSTM, поданий на рисунку 4.4.

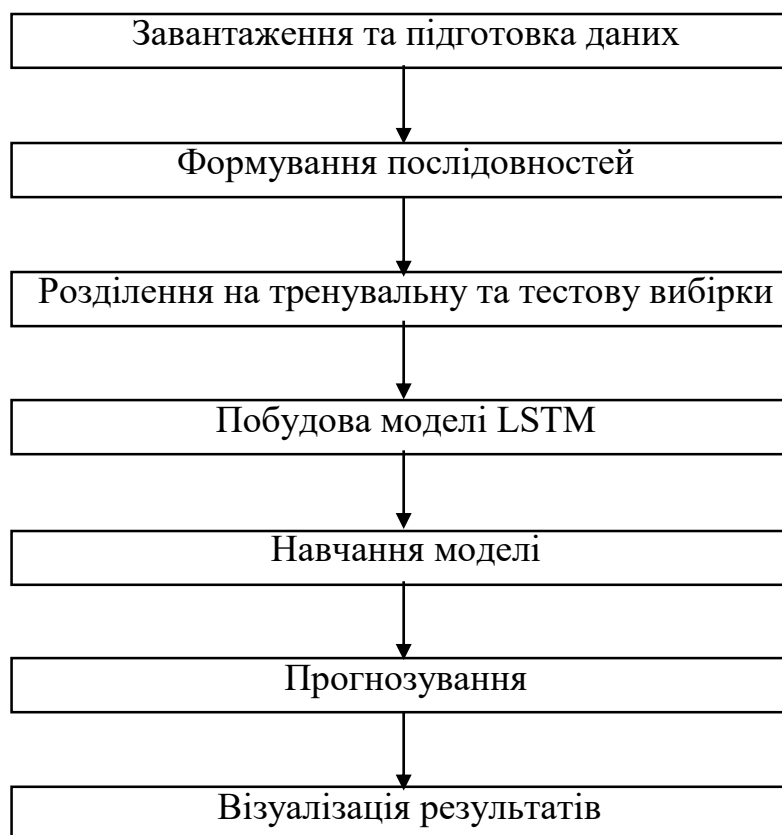


Рисунок 4.4 – Схема алгоритму прогнозування цінових рухів на фінансових ринках за допомогою рекурентної нейронної мережі LSTM

Програмний код алгоритму прогнозування цінових рухів на фінансових ринках за допомогою рекурентної нейронної мережі LSTM, поданий у додатку Г.

Даний код на мові програмування Python демонструє розробку алгоритму прогнозування цінових рухів на фінансових ринках за допомогою рекурентної нейронної мережі LSTM. У цьому прикладі використовується історична інформація про закриття цін (Close) з CSV-файлу, дані нормалізуються, формуються часові послідовності, після чого модель навчається прогнозувати наступне значення ціни на основі попередніх 60 днів.

Результати прогнозування візуалізуються для порівняння фактичних і прогнозованих значень.

Використовується колонка Close для прогнозування цінових рухів. Дані нормалізуються за допомогою MinMaxScaler для стабільнішого навчання моделі.

Встановлюється `sequence_length = 60`, що означає, що для кожного прогнозу використовується інформація за останні 60 днів. Формуються вхідні послідовності X та цільові значення y .

Вхідні дані X перетворюються у формат `[samples, timesteps, features]`. Побудована двошарова LSTM модель з додаванням Dropout для уникнення перенавчання. Модель компілюється з оптимізатором adam та функцією втрат `mean_squared_error`. Модель навчається на тренувальних даних протягом 50 епох із валідаційним розподілом. Прогнозовані значення денних цін отримуються на тестовій вибірці, після чого вони денормалізуються для порівняння з фактичними значеннями.

Цей приклад можна адаптувати залежно від конкретних вимог, наприклад, додати додаткові ознаки (обсяги торгів, технічні індикатори), використовувати інші архітектури нейронних мереж або налаштувати параметри моделі для досягнення кращої точності прогнозування.

4.3 Створення моделей для автоматизованої торгівлі

Первинним етапом є формулювання торгової стратегії, яка враховує специфіку ринкових умов, динаміку обсягів торгів, а також ризики, пов'язані із змінами цінових рухів. Для цього проводиться детальний аналіз історичних даних, включаючи часові ряди цін, технічні індикатори та обсяги торгів, що дозволяє виявити закономірності та патерни, які можуть бути використані для генерації торгових сигналів.

На основі отриманих даних обирається відповідний підхід до розробки торгової моделі. Одним із найперспективніших напрямків є

застосування методів підсиленого навчання (Reinforcement Learning), де торговий агент взаємодіє з ринком, отримуючи винагороди за прибуткові операції та штрафи за збиткові, що дозволяє моделі самонавчатись на основі власного досвіду. Такий підхід сприяє створенню адаптивної торгової стратегії, яка може ефективно реагувати на змінні ринкові умови та оптимізувати процес прийняття рішень. Крім того, розглядаються ансамблеві методи, що об'єднують прогнози різних моделей (наприклад, LSTM для прогнозування цінових тенденцій у поєднанні з моделями регресії та дерева рішень для оцінки ризиків), що дозволяє підвищити загальну точність та стійкість торгової системи.

Наступним етапом є створення прототипу торгової системи, яка інтегрує розроблену модель у платформу автоматизованої торгівлі. Така система включає модулі для збору та обробки ринкових даних у режимі реального часу, генерації торгових сигналів та їх автоматичного виконання. Особлива увага приділяється розробці системи управління ризиками, яка реалізується через використання стоп-лоссів, трейлінг-стопів та алгоритмів управління розміром позицій. Це дозволяє зменшити можливі збитки та забезпечити стабільність роботи системи навіть у періоди високої ринкової невизначеності.

Для оцінки ефективності створених торгових моделей проводиться комплексне тестування, що включає як історичне тестування (backtesting) на базі архівних даних, так і forward testing (paper trading) у режимі реального часу. Аналіз отриманих результатів за допомогою ключових метрик, таких як коефіцієнт Шарпа, максимальна просадка та прибутковість, дозволяє визначити сильні та слабкі сторони розроблених підходів, оптимізувати гіперпараметри та внести необхідні корективи. Результатом цього процесу є створення інтегрованої системи, яка здатна автоматично генерувати торгові сигнали, адаптуватися до змін ринкової кон'юнктури та управляти ризиками, що є надзвичайно важливим для забезпечення стабільного прибутку в умовах сучасного ринку.

Отже, розробка моделей для автоматизованої торгівлі охоплює весь цикл – від аналізу ринкових даних та формулювання торгової стратегії до інтеграції алгоритмів у систему реального часу з налаштованими механізмами управління ризиками. Використання сучасних методів машинного навчання, зокрема підсиленого навчання та ансамблевих підходів, дозволяє створити адаптивну та ефективну торгову систему, що здатна оперативно реагувати на ринкові зміни і сприяти прийняттю обґрунтованих інвестиційних рішень.

Схема алгоритму створення моделі для автоматизованої торгівлі за допомогою підсиленого навчання, поданий на рисунку 4.5.



Рисунок 4.5 – Схема алгоритму створення моделі для автоматизованої торгівлі за допомогою підсиленого навчання

Програмний код створення моделі для автоматизованої торгівлі за допомогою підсиленого навчання, поданий у додатку Д.

Даний код на мові програмування Python демонструє створення моделі для автоматизованої торгівлі за допомогою підсиленого навчання (Reinforcement Learning) із використанням бібліотеки `stable-baselines3` та середовища `gym-anytrading`.

У цьому прикладі дані про історичні ціни завантажуються з CSV-файлу, створюється середовище для торгівлі (StocksEnv), після чого агент, використовуючи алгоритм PPO (Proximal Policy Optimization), навчається генерувати торгові сигнали.

Після навчання агент проходить тестування, а результати візуалізуються для аналізу ефективності торгової стратегії.

Середовище stocks-v0 із бібліотеки gym-anytrading створюється на основі завантажених даних. Параметр window_size задає кількість попередніх днів, які використовуються як контекст для прийняття рішення, а frame_bound визначає інтервал даних, який буде використовуватися для симуляції торгівлі. Середовище обгортається за допомогою DummyVecEnv для забезпечення сумісності з алгоритмами з stable-baselines3.

Навчання агента. Використовується алгоритм PPO із політикою «MlpPolicy» (багатошаровий перцептрон), який навчається протягом 10 000 кроків (timesteps). Параметр verbose=1 дозволяє відслідковувати процес навчання в консолі.

Після навчання агент запускається у режим тестування, де для кожного спостереження генерується дія, яка виконується у середовищі. Функція env.render() показує поточний стан середовища (торгові сигнали, позиції, графік ціни тощо).

Тестування проводиться на тренувальних, валідаційних та тестових наборах даних для перевірки здатності моделі до генералізації [32, с. 696].

Після завершення тестування викликається env.render_all(), що дозволяє отримати підсумкову візуалізацію результатів торгової стратегії.

Цей приклад демонструє базову інтеграцію алгоритмів підсиленого навчання у середовище автоматизованої торгівлі. У реальному проєкті можна розширити функціонал, включаючи додаткові індикатори, розширене управління ризиками, оптимізацію гіперпараметрів та інтеграцію з реальними брокерськими API для виконання торгових операцій.

4.4 Валідація та оптимізація торгових алгоритмів

У сучасних умовах високої волатильності та швидкоплинності ринкових умов ефективність торгових алгоритмів значною мірою залежить від їхньої здатності адекватно реагувати на зміни ринку, а також від надійної роботи у різних сценаріях торгівлі. Саме тому валідація та оптимізація торгових алгоритмів є критичними етапами при розробці систем автоматизованої торгівлі, які мають забезпечити не лише прибутковість, але й стабільність та контроль ризиків.

Традиційні методи управління фінансами часто не враховують індивідуальних особливостей користувачів та не здатні оперативно адаптуватися до змін у фінансовій поведінці. Люди стикаються з труднощами в плануванні бюджету, контролі витрат та прийнятті інвестиційних рішень. Відсутність персоналізованих рекомендацій може призвести до фінансових втрат та зниження добробуту [33, с. 578].

Важливою задачею є розробка інтелектуальних систем, здатних у режимі реального часу обробляти фінансові дані, враховувати їхню волатильність та невизначеність, а також надавати персоналізовані рекомендації користувачам [34, с. 79].

Першим кроком у цьому процесі є проведення ретроспективного тестування (backtesting), яке полягає у застосуванні розробленої торгової стратегії до історичних даних. Завдяки цьому можна отримати уявлення про те, як алгоритм поведив би себе в минулому, виявити потенційні слабкі місця, перевірити логіку прийняття рішень, а також оцінити прибутковість стратегії за різних ринкових умов. Важливою задачею при проведенні backtesting є забезпечення максимальної реалістичності симуляції: врахування комісій брокера, спредів, швидкості виконання замовлень, а також можливих затримок у отриманні даних. Також слід зазначити, що історичні дані не завжди можуть повністю відобразити майбутню ринкову

поведінку, тому результати ретроспективного тестування слід сприймати як орієнтовні індикатори ефективності стратегії.

Наступним етапом є forward testing або paper trading, який проводиться на більш свіжих даних або в режимі симуляції реальної торгівлі без фактичного розміщення замовлень. Цей підхід дозволяє перевірити адаптивність та стабільність торгової стратегії в умовах поточної ринкової кон'юнктури, виявити можливі недоліки в логіці прийняття рішень, а також оцінити, наскільки алгоритм здатний адаптуватися до змін у ринкових умовах. Forward testing є важливим етапом, оскільки він допомагає уникнути перенавчання моделі на історичних даних (overfitting) та забезпечити її здатність до узагальнення при роботі з новою інформацією.

Паралельно з валідацією проводиться оптимізація торгових алгоритмів, що включає підбір оптимальних гіперпараметрів моделі, оптимізацію параметрів торгової стратегії та налаштування системи управління ризиками. Процес оптимізації може здійснюватися за допомогою перебору параметрів (grid search), випадкового пошуку (random search) або більш просунутих методів, таких як байєсівська оптимізація. Основними метриками, за якими проводиться оцінка ефективності під час оптимізації, є коефіцієнт Шарпа, максимальна просадка (DrawDown), загальна прибутковість, співвідношення вигравів до програшів, а також інші показники, що дозволяють комплексно оцінити не лише прибутковість, але й ризиковість стратегії.

Оптимізація торгових алгоритмів також включає тестування їхньої стійкості в умовах стрес-тестування, коли симулюються екстремальні ринкові ситуації, такі як «чорні лебеді» або різкі зміни волатильності. Такий підхід дозволяє виявити можливі вразливості стратегії та розробити додаткові механізми захисту, зокрема системи автоматичного виходу з позиції, стоп-лоси та трейлінг-стопи. У цьому контексті особливе значення набуває інтеграція модулів управління ризиками, що дозволяють

адаптувати стратегію до змін ринкових умов у режимі реального часу та знижувати потенційні збитки.

Загалом, процес валідації та оптимізації торгових алгоритмів є багатограним та інтегрованим циклом, що охоплює ретельну перевірку моделі на історичних даних, її адаптацію до поточних ринкових умов та оптимізацію параметрів з метою максимізації прибутковості при мінімізації ризиків. Ретельна валідація дозволяє забезпечити надійність і стабільність торгової стратегії, а систематична оптимізація сприяє покращенню її роботи у реальних умовах торгівлі. Отримані результати вказують на потенціал подальшого вдосконалення алгоритмів, що може стати основою для створення високоефективних систем автоматизованої торгівлі, здатних адаптуватися до постійних змін ринкової кон'юнктури та забезпечувати стабільний дохід.

Схема алгоритму процесу валідації та оптимізації торгових алгоритмів, поданий на рисунку 4.6.



Рисунок 4.6 – Схема алгоритму процесу валідації та оптимізації торгових алгоритмів

Програмний код процесу валідації та оптимізації торгових алгоритмів, поданий у додатку Е.

Даний код на мові програмування Python демонструє процес валідації та оптимізації торгових алгоритмів із застосуванням бібліотеки Backtrader.

У цьому прикладі реалізовано просту стратегію на основі перетину двох ковзних середніх (moving average crossover), після чого здійснюється оптимізація параметрів (періодів для швидкої та повільної ковзної середньої) із використанням вбудованого механізму оптимізації Backtrader.

Для оцінки ефективності кожної комбінації параметрів застосовуються аналітики, такі як Sharpe Ratio та максимальна просадка (DrawDown).

Результатом оптимізації є вибір параметрів, що забезпечують найвищий Sharpe Ratio при прийнятному рівні ризику.

Визначена стратегія MovingAverageCrossStrategy використовує дві ковзні середні – швидку та повільну.

Сигнал на купівлю виникає, коли швидка ковзна перетинає повільну знизу вгору, а сигнал на продаж – коли відбувається зворотне перетинання.

Об'єкт Cerebro завантажує історичні дані (в даному прикладі використовується акція AAPL з Yahoo Finance) та встановлює початковий капітал.

Також додаються аналітики для розрахунку Sharpe Ratio та DrawDown для оцінки ефективності стратегії.

За допомогою методу optstrategy проводиться перебір комбінацій параметрів: параметр fast_period перебирається значеннями 5, 10 та 15, а slow_period – 20, 30 та 40. Для кожної комбінації проводиться симуляція, а результати оцінюються за допомогою зазначених аналітиків.

Після завершення оптимізації проходиться по всіх запущених варіантах стратегії, для кожного виводиться Sharpe Ratio та максимальна просадка. Параметри з найвищим Sharpe Ratio вважаються найкращими.

Цей код демонструє базовий підхід до валідації та оптимізації торгових алгоритмів із використанням історичних даних (backtesting).

Для практичного застосування можна розширити модель, додати додаткові аналітики, більш складні стратегії, а також використовувати паралельну оптимізацію для скорочення часу розрахунків.

Загалом, результати розділу свідчать про те, що сучасні методи машинного навчання та штучного інтелекту мають значний потенціал для підвищення ефективності автоматизованої торгівлі.

Розроблені алгоритми демонструють високу точність прогнозування та здатність адаптуватися до змін ринкової кон'юнктури, що створює міцну основу для подальшого вдосконалення торгових стратегій.

5 УЗАГАЛЬНЕННЯ РЕЗУЛЬТАТІВ ТА ПЕРСПЕКТИВИ РОЗВИТКУ

5.1 Аналіз отриманих результатів та їх порівняння з існуючими рішеннями

У даному підрозділі проведено всебічний аналіз результатів, отриманих у ході дослідження, а також здійснено порівняння розроблених моделей з існуючими рішеннями у сфері автоматизації ведення особистих фінансів та алгоритмічної торгівлі на фінансових ринках.

По-перше, розроблені алгоритми прогнозування витрат і доходів, класифікації та кластеризації фінансових транзакцій дозволили досягти високої точності аналізу історичних даних. Використання методів машинного навчання, зокрема моделей регресії, дерев рішень та нейронних мереж, забезпечило можливість виявлення прихованих залежностей у фінансових часових рядах та сформуванню надійний прогноз майбутніх фінансових потоків. Порівняно з традиційними статистичними методами, запропоновані алгоритми демонструють вищу адаптивність до змін у ринкових умовах, що є особливо важливим для управління особистими фінансами. Крім того, застосування класифікаційних та кластеризаційних моделей дозволило ефективно групувати транзакції за категоріями та виявляти аномальні операції, що сприяє оптимізації процесу фінансового аналізу.

По-друге, у розділі 4 було розроблено моделі для автоматизованої торгівлі на фінансових ринках із застосуванням методів глибинного навчання та підсиленого навчання. Рекурентні нейронні мережі типу LSTM забезпечили точне прогнозування цінових рухів, що є основою для формування торгових сигналів. У свою чергу, використання алгоритмів підсиленого навчання (наприклад, PPO у середовищі gym-anytrading) дозволило створити адаптивного торгового агента, здатного приймати оперативні рішення в умовах високої волатильності. Ці підходи

демонструють значне поліпшення в порівнянні з класичними методами алгоритмічної торгівлі, які базуються на статичних правилах і технічному аналізі, оскільки інтегровані моделі здатні ефективно реагувати на швидкі зміни ринкової кон'юнктури.

По-третє, проведена валідація та оптимізація торгових алгоритмів засвідчили, що систематичний підхід до тестування – за допомогою *backtesting*, *forward testing* та стрес-тестування – дозволяє не лише оцінити прибутковість стратегії, але й виявити слабкі місця у моделюванні ризиків. Використання таких метрик, як коефіцієнт Шарпа, максимальна просадка та співвідношення виграшів до програшів, дозволило об'єктивно порівняти ефективність розроблених алгоритмів із аналогічними рішеннями, представленими в науковій літературі та комерційних системах. Отримані результати свідчать про конкурентні переваги розроблених підходів у плані адаптивності, гнучкості налаштування та здатності працювати в умовах високої ринкової невизначеності.

Порівняльний аналіз із існуючими рішеннями показав, що запропоновані алгоритми мають низку суттєвих переваг. По-перше, інтеграція сучасних методів машинного навчання забезпечує більш точне прогнозування та виявлення трендів у фінансових даних. По-друге, застосування підсиленого навчання дозволяє створити адаптивні торгові системи, здатні оперативно реагувати на зміни ринку, що є недоступним для традиційних систем, заснованих на статичних правилах. По-третє, можливість гнучкого налаштування моделей, а також використання ансамблевих підходів сприяє підвищенню стійкості та ефективності систем управління ризиками.

Таким чином, аналіз отриманих результатів показує, що розроблені алгоритми не лише відповідають сучасним вимогам автоматизації фінансової діяльності, але й демонструють значні переваги над традиційними методами. Отримані дані свідчать про високий потенціал подальшого вдосконалення та інтеграції цих рішень у комерційні системи

автоматизованої торгівлі та управління особистими фінансами, що відкриває широкі перспективи для практичного застосування розроблених технологій.

5.2 Рекомендації щодо впровадження розроблених алгоритмів

На підставі проведеного дослідження та отриманих результатів доцільно виділити низку рекомендацій щодо впровадження розроблених алгоритмів у практичні системи автоматизації ведення особистих фінансів та алгоритмічної торгівлі.

По-перше, необхідно забезпечити інтеграцію алгоритмів у існуючу IT-інфраструктуру компаній або фінансових установ із врахуванням стандартів безпеки даних та конфіденційності. Важливо використовувати сучасні технології контейнеризації (Docker, Kubernetes) для забезпечення гнучкості розгортання, масштабованості системи та можливості оперативного оновлення моделей без зупинки основних бізнес-процесів.

По-друге, рекомендується здійснювати періодичне оновлення тренувальних даних та перенавчання алгоритмів із використанням методів online learning або transfer learning. Це дозволить адаптувати моделі до змін ринкової кон'юнктури, покращувати їхню точність та забезпечувати стабільну роботу у режимі реального часу. У зв'язку з цим доцільно впровадити автоматизовані процеси збору, очищення та попередньої обробки даних, що дозволить оперативно реагувати на змінні умови ринку та мінімізувати вплив «шуму» у даних.

Третім рекомендаційним напрямком є використання модульного підходу при розробці програмних продуктів, що включає розподіл системи на окремі компоненти: модуль прогнозування, модуль класифікації транзакцій, модуль аналізу ризиків та управління позиціями. Така архітектура дозволить не лише спростити процес впровадження та підтримки системи, але й забезпечить можливість швидкої інтеграції

додаткових функціональних блоків, наприклад, модулів для обробки новин або соціальних медіа, що можуть впливати на ринкові процеси.

Четвертим аспектом є впровадження механізмів моніторингу та контролю якості роботи алгоритмів. Для цього слід створити систему аналітики, що забезпечує збір та обробку метрик, таких як точність прогнозів, коефіцієнт Шарпа, максимальна просадка та інші індикатори ефективності. Такий підхід дозволить виявляти можливі збої у роботі моделей, оперативно вносити корективи та проводити регулярні стрес-тести для перевірки стійкості системи в умовах екстремальних ринкових змін.

П'ятий напрямок стосується організаційних та регуляторних питань. Рекомендовано забезпечити відповідність впроваджуваних алгоритмів чинному законодавству у сфері захисту персональних даних, фінансової звітності та дотримання нормативів фінансового регулювання. Співпраця із юридичними та аудиторськими структурами дозволить не лише мінімізувати ризики санкцій, але й підвищити довіру користувачів до системи.

Загалом, впровадження розроблених алгоритмів має здійснюватися поетапно із початковою апробацією у вигляді пілотного проекту, що дозволить провести комплексну оцінку роботи системи у реальних умовах та виявити можливі недоліки.

Отриманий досвід слід використовувати для подальшої адаптації та вдосконалення моделей із врахуванням специфіки діяльності організації та вимог ринку.

Такі підходи сприятимуть ефективному використанню сучасних технологій машинного навчання, підвищенню якості управління фінансами та оптимізації торгових процесів, що в кінцевому рахунку забезпечить конкурентні переваги на ринку фінансових послуг.

5.3 Перспективи подальших досліджень у даному напрямку

Подальші дослідження у сфері застосування машинного навчання для автоматизації ведення особистих фінансів та алгоритмічної торгівлі відкривають широкі перспективи для розвитку як теоретичних моделей, так і практичних рішень. Сучасні технології дозволяють інтегрувати дані з різних джерел, що сприяє більш глибокому аналізу ринкових процесів та прийняттю обґрунтованих рішень. Одним із напрямків подальших досліджень є розширення спектру використовуваних даних та ознак. Наприклад, інтеграція соціальних медіа, новинних стрічок, макроекономічних показників і поведінкових даних користувачів може суттєво підвищити точність прогнозів і дозволити будувати більш комплексні моделі, здатні враховувати як структуровану, так і неструктуровану інформацію.

Іншим перспективним напрямком є розробка моделей із застосуванням новітніх архітектур глибокого навчання, зокрема трансформерів, які вже показали високий потенціал у роботі з послідовними даними. Такий підхід може дозволити значно покращити обробку часових рядів та виявлення довгострокових залежностей у фінансових даних. Водночас варто звернути увагу на використання мультиагентних систем і підсиленого навчання, що відкриває можливості для розробки адаптивних торгових стратегій. Дослідження, спрямовані на створення агентів, які взаємодіють між собою або працюють у складі гібридних систем, можуть забезпечити більш комплексне моделювання ринкових умов і підвищити ефективність прийняття рішень у режимі реального часу.

Особливо актуальним є питання інтерпретованості та пояснюваності моделей машинного навчання. Забезпечення прозорості прийнятих рішень не лише сприятиме підвищенню довіри користувачів, але й допоможе виявити слабкі місця моделей, що дозволить оперативно вносити корективи. Дослідження у цьому напрямку можуть включати розробку методів

візуалізації та аналізу впливу окремих ознак на фінальний прогноз, а також використання технологій explainable AI.

Крім того, важливим аспектом є інтеграція систем управління ризиками із застосуванням машинного навчання. Подальші дослідження можуть бути спрямовані на розробку моделей, що прогнозують можливість ринкових збоїв, максимальну просадку портфеля або ймовірність виникнення екстремальних подій, що допоможе створити більш адаптивні та надійні торгові стратегії. Такий підхід, поєднаний із використанням ансамблевих методів та гібридних рішень, може сприяти зниженню фінансових ризиків і оптимізації управління капіталом.

Перспективи подальших досліджень у даному напрямку пов'язані з:

- розширенням набору даних та використанням мультиджерельної інформації;
- використанням сучасних архітектур глибинного навчання (трансформери, мультиагентні системи);
- розробкою методів забезпечення пояснюваності рішень моделей;
- інтеграцією розширених систем управління ризиками.

Це свідчить про високий потенціал розроблених алгоритмів для автоматизації фінансового аналізу та торгівлі, необхідність подальших досліджень і вдосконалення моделей з метою їх ефективної інтеграції у комерційні рішення, що забезпечуватимуть конкурентні переваги на ринку.

ВИСНОВКИ

Проведене дослідження демонструє високий потенціал застосування методів машинного навчання для автоматизації ведення особистих фінансів та алгоритмічної торгівлі на фінансових ринках. Загальна мета роботи полягала у розробці, аналізі та програмній реалізації моделей машинного навчання, спрямованих на покращення ефективності управління особистими фінансами та прийняття рішень при торгівлі на ринках.

Першочерговим результатом дослідження стало формування теоретичних та методологічних основ використання машинного навчання у фінансовій сфері, що включає аналіз сучасних підходів, алгоритмів та технологій, а також визначення факторів, що впливають на їх ефективність. Проведений огляд літератури та аналіз існуючих рішень дозволив встановити, що традиційні статистичні методи часто не здатні адекватно відобразити динаміку ринкових процесів, а інтелектуальні алгоритми на базі машинного навчання демонструють значно кращі результати в умовах нестабільності та високої складності даних.

Розроблені в роботі алгоритми для автоматизації ведення особистих фінансів, зокрема моделі прогнозування витрат та доходів, а також методи класифікації і кластеризації фінансових транзакцій, продемонстрували високу точність, адаптивність та можливість виявлення прихованих закономірностей у фінансових потоках. Ретельне тестування, що включало крос-валідацію, backtesting та forward testing, дозволило не лише оцінити якість розроблених моделей, але й виявити їхні сильні та слабкі сторони, що є важливим для подальшої оптимізації та інтеграції у практичні системи.

У сфері алгоритмічної торгівлі застосування методів глибинного навчання, зокрема рекурентних нейронних мереж (LSTM) для прогнозування цінових рухів, а також алгоритмів підсиленого навчання для створення адаптивних торгових агентів, показало значне покращення точності прийняття рішень. Розроблені торгові стратегії, що включають

інтегровані механізми управління ризиками, продемонстрували конкурентні переваги порівняно з традиційними підходами, що базуються на статичних правилах і технічному аналізі.

Авторські пропозиції, сформульовані в роботі, включають рекомендації щодо впровадження розроблених алгоритмів у комерційні продукти, зокрема використання сучасних технологій контейнеризації, автоматизації оновлення даних та модульного підходу до розробки систем. Також відзначено необхідність подальших досліджень у напрямку розширення набору використовуваних ознак, інтеграції мультиджерельної інформації, застосування новітніх архітектур глибинного навчання та розробки методів забезпечення пояснюваності прийнятих рішень.

Отже, результати роботи свідчать про доцільність і ефективність застосування машинного навчання для автоматизації фінансового аналізу та алгоритмічної торгівлі. Отримані висновки відкривають перспективи для подальшої розробки інтелектуальних систем, здатних адаптуватися до швидкозмінних ринкових умов, оптимізувати управління фінансами та забезпечувати конкурентні переваги на ринку фінансових послуг.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Orzechowski A. Is there still room for increasing speed in algorithmic and high-frequency trading? the case of european options priced in the heston model. *Metody Ilościowe W Badaniach Ekonomicznych*. 2019. Vol. 20, No. 1. P. 35–44. URL: <https://qme.sggw.edu.pl/article/view/2462> (дата звернення: 30.04.2025).
2. Smith G. Be Wary of Black-Box Trading Algorithms. *Journal of Investing*. 2019. Vol. 32, No. 3. P. 7–15. URL: https://scholarship.claremont.edu/cgi/viewcontent.cgi?article=1007&context=po_mona_fac_econ (дата звернення: 30.04.2025).
3. Atkins A., Dyl E. Market structure and reported trading volume : NASDAQ VERSUS THE NYSE. *Journal of Financial Research*. 2014. No. 3 (20). P. 291–304. URL: <https://onlinelibrary.wiley.com/doi/10.1111/j.1475-6803.1997.tb00250.x> (дата звернення: 30.04.2025).
4. Culley A. Does the deployment of algorithms combined with direct electronic access increase conduct risk? Evidence from the LME. *Journal of Financial Regulation and Compliance*. 2023. No. 2 (31). P. 220–236. URL: <https://www.emerald.com/insight/content/doi/10.1108/JFRC-04-2022-0046/full/html> (дата звернення: 30.04.2025).
5. High Speed Equities Trading : 1993–2012. *Asia-Pacific Journal of Financial Studies*. 2015. No. 6 (43). P. 767–797. URL: <https://onlinelibrary.wiley.com/doi/10.1111/ajfs.12078> (дата звернення: 30.04.2025).
6. Frino A. et al. An empirical analysis of algorithmic trading around earnings announcements. *Pacific-Basin Finance Journal*. 2017. No. 45. P. 34–51. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0927538X16300/531?via%3Dihub> (дата звернення: 30.04.2025).
7. Frino A. et al. The Effect of Algorithmic Trading On Market Liquidity: Evidence Around Earnings Announcements On Borsa Italiana. *Pacific-Basin*

Finance Journal. 2017. No. 45. P. 82–90. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0927538X16300956?via%3Dihub> (дата звернення: 30.04.2025).

8. Ozturk M., Hakki I., Fidan G. Heuristic based trading system on Forex data using technical indicator rules. *Applied Soft Computing*. 2016. No. 43. P. 170–186. URL: <https://www.sciencedirect.com/science/article/abs/pii/S1568494616300369?via%3Dihub> (дата звернення: 30.04.2025).

9. Sumantri M., Yudawisastra H., Handanu R. How Fundamental Analysis and Technical Analysis Determining The Stock Price : Case Study Of Mining Company Listed On The Indonesia Stock Exchange. *International Journal of Trade, Economics and Finance*. 2018. No. 6 (10). P. 273–276. URL: <http://www.ijtef.org/index.php?m=content&c=index&a=show&catid=96&id=977> (дата звернення: 30.04.2025).

10. Hyungjun P., Kyu S., Gu C. An Intelligent Financial Portfolio Trading Strategy Using Deep Q-learning. *Quantitative Finance*. 2019. URL: <https://arxiv.org/pdf/1907.03665.pdf> (дата звернення: 30.04.2025).

11. Jakel M., Sosik P. Genetically Evolved Agents for Stock Price Prediction. *Acta Polytechnica Hungarica*. 2013. No. 2 (10). P. 21–35. URL: http://acta.uni-obuda.hu/Jakel_Sosik_40.pdf (дата звернення: 30.04.2025).

12. Bishop C. M. *Pattern Recognition and Machine Learning*. Springer, 2006. URL: <https://www.microsoft.com/en-us/research/wp-content/uploads/2006/01/Bishop-Pattern-Recognition-and-Machine-Learning-2006.pdf> (дата звернення: 30.04.2025).

13. Goodfellow, I., Bengio, Y., Courville A. *Deep Learning*. MIT Press. 2016. URL: <https://www.deeplearningbook.org/contents/prob.html> (дата звернення: 30.04.2025).

14. Hastie, T., Tibshirani, R., & Friedman, J. *The Elements of Statistical Learning : Data Mining, Inference, and Prediction*. Springer. 2009. URL:

<https://www.sas.upenn.edu/~fdiebold/NoHesitations/BookAdvanced.pdf> (дата звернення: 30.04.2025).

15. Murphy K. P. *Machine Learning: A Probabilistic Perspective*. MIT Press. 2012. URL: <https://static.googleusercontent.com/media/research.google.com/ru//pubs/archive/38136.pdf> (дата звернення: 30.04.2025).

16. James G., Witten D., Hastie T., Tibshirani R. *An Introduction to Statistical Learning: with Applications in R*. Springer. 2013. URL: <https://static1.squarespace.com/static/5ff2adbe3fe4fe33db902812/t/6009dd9fa7bc363aa822d2c7/1611259312432/ISLR+Seventh+Printing.pdf> (дата звернення: 30.04.2025).

17. Sutton R. S., Barto A. G. *Reinforcement Learning: An Introduction*. MIT Press. 2018. URL: <https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf> (дата звернення: 30.04.2025).

18. Kuhn M., Johnson K. *Applied Predictive Modeling*. Springer. 2013. URL: https://vuquangnguyen2016.wordpress.com/wp-content/uploads/2018/03/applied-predictive-modeling-max-kuhn-kjell-johnson_1518.pdf (дата звернення: 30.04.2025).

19. Aggarwal C. C. *Neural Networks and Deep Learning: A Textbook*. Springer. 2018. URL: http://www.ndl.ethernet.edu.et/bitstream/123456789/88552/1/2018_Book_NeuralNetworksAndDeepLearning.pdf (дата звернення: 30.04.2025).

20. Shalev-Shwartz S., Ben-David S. *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press. 2014. URL: <https://www.cs.huji.ac.il/~shais/UnderstandingMachineLearning/understanding-machine-learning-theory-algorithms.pdf> (дата звернення: 30.04.2025).

21. Наука про дані: машинне навчання та інтелектуальний аналіз даних. Електронний навчальний посібник / за ред. Мокін В. Б., Дратований М. В. Вінниця : ВНТУ, 2024. 263 с.

22. Модель мультиагентної системи автономного адміністрування інформаційних систем та розподілених баз даних Філатов В. А., Цибульник І., Чала Л. Е. *Новини штучного інтелекту*. 2002. URL: http://iai.dn.ua/public/JournalAI_2002_4/Razdel5/13_Filatov.pdf (дата звернення: 30.04.2025).

23. Гришко А. А., Удовенко С. М., Чала Л. Е. Гібридні методи машинного навчання у системах управління динамічними об'єктами, *Біоніка інтелекту : наук.-техн. журнал*. 2012. № 1 (78). С. 78–84. URL: <https://openarchive.nure.ua/server/api/core/bitstreams/52974df9-bfc9-49ab-8f67-ccfcb34b293/content> (дата звернення: 30.04.2025).

24. Russell S. J., Norvig P. *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson. 2020. URL: http://lib.yzu.am/disciplines_bk/efdd4d1d4c2087fe1cbe03d9ced67f34.pdf (дата звернення: 30.04.2025).

25. Сергєєв О. А. *Інтелектуальний аналіз даних : підручник*. Київ: Видавництво Ліра-К., 2018. URL: <https://ela.kpi.ua/server/api/core/bitstreams/53cc4098-de84-4297-862f-d9ae3a586546/content> (дата звернення: 30.04.2025).

26. Lopez de Prado, M. *Advances in Financial Machine Learning*. Wiley. 2018. URL: <https://agorism.dev/book/finance/ml/Marcos%20Lopez%20de%20Prado%20-%20Advances%20in%20Financial%20Machine%20Learning-Wiley/%20%282018%29.pdf> (дата звернення: 30.04.2025).

27. Chan E. P. *Machine Trading: Deploying Computer Algorithms to Conquer the Markets*. Wiley. 2017. URL: [https://github.com/gudbrandtandberg/CPSC540Project/blob/master/Machine%20Trading:%20Deploying%20Computer%20Algorithms%20to%20Conquer%20The%20Markets%20\(Ernest%20Chan%202017\).pdf](https://github.com/gudbrandtandberg/CPSC540Project/blob/master/Machine%20Trading:%20Deploying%20Computer%20Algorithms%20to%20Conquer%20The%20Markets%20(Ernest%20Chan%202017).pdf) (дата звернення: 30.04.2025).

28. Hilpisch Y. Python for Finance: Mastering Data-Driven Finance, 2018. URL: [https://www.sea-stat.com/wp-content/uploads/2021/05/Yves-Hilpisch-Python-for-Finance -Mastering-Data-Driven-Finance-Book-OReilly-2018.pdf](https://www.sea-stat.com/wp-content/uploads/2021/05/Yves-Hilpisch-Python-for-Finance-Mastering-Data-Driven-Finance-Book-OReilly-2018.pdf) (дата звернення: 30.04.2025).
29. Fischer T., Krauss C. Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*. Vol. 270, No. 2. 2018. P. 654–669. URL: <https://iranarze.ir/wp-content/uploads/2019/01/E10789-IranArze.pdf> (дата звернення: 30.04.2025).
30. Hull J. C. Options, Futures, and Other Derivatives (11th ed.). *Pearson*. 2021. URL: https://imp.dayawisesa.com/wp-content/uploads/2023/10/John_Hull_Options_Futures_and_Other_Derivatives_Pearson_2021-1.pdf (дата звернення: 30.04.2025).
31. Штучний інтелект у науці та освіті (AISE 2024). Artificial intelligence in science and education : збірник матеріалів міжнародної наукової конференції (Київ, 1–2 березня 2024 р.) / упоряд: А. Яцишин, В. Матусевич, В. Коваленко. Київ : УкрІНТЕІ, 2024. 600 с.
32. Інформаційні технології і автоматизація – 2024 : Матеріали XVII міжнародної науково-практичної конференції. Одеса, 31 жовтня – 1 листопада 2024 р. Одеса : Видавництво ОНТУ, 2024. 847 с.
33. Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : Тези доповідей XII Міжнародної науково-практичної конференції (10–12 грудня 2024 р., м. Запоріжжя). [Електронний ресурс]. Запоріжжя : НУ «Запорізька політехніка», 2024. 500 с. 1 електрон. опт. диск (DVD-ROM).
34. 29-й Міжнародний молодіжний форум «Радіоелектроніка та молодь у XXI столітті». Зб. матеріалів форуму. Т. 6. Харків : ХНУРЕ, 2025. 630 с.