Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)
Кафедра Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти перший (бакалаврський)

Розробка алгоритму створення інвестиційних портфоліо на основі алгоритмів машинного навчання
(тема)

Виконав:
здобувач четвертого року навчання,
групи ІТШІ-21-3

Анна Іванченко
(власне ім'я, прізвище)

Спеціальність 122 Комп'ютерні науки

(код і повна назва спеціальності)
Тип програми освітньо-професійна
Освітня програма Штучний інтелект

(повна назва освітньої програми)
Керівник доц. Ігор Магдаліна
(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ШІ _____ Олег ЗОЛОТУХІН
(підпис) (власне ім'я, прізвище)

2025 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук

Кафедра Штучного інтелекту

Рівень вищої освіти перший (бакалаврський)

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

Тип програми освітньо-професійна

Освітня програма Штучний інтелект
(повна назва)

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

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві Іванченко Анні Михайлівні
(прізвище, ім'я, по батькові)

1. Тема роботи Розробка алгоритму створення інвестиційних портфоліо на основі алгоритмів машинного навчання

затверджена наказом університету від 19 травня 20 25 р. № 265Ст
2. Термін подання студентом роботи до екзаменаційної комісії 20 червня 20 25 р.
3. Вихідні дані до роботи Науково-технічні публікації, дані Інтернет-джерел та відомих наукових проєктів, PyPortfolioOpt документація, Flask документація,

4. Перелік питань, що потрібно опрацювати в роботі
1) Аналіз та постановка задачі
2) Огляд існуючих алгоритмів та систем автоматизації портфоліо
3) Розробка алгоритму створення інвестиційного портфоліо
4) Демонстрація роботи алгоритму на веб-платформі

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / терміни виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	19.05.2025	виконано
2	Аналіз предметної галузі	25.05.2025	виконано
3	Дослідження сучасної теорії портфоліо	26.05.2025	виконано
4	Дослідження методів машинного навчання при	29.05.2025	виконано
5	Створення інвестиційного портфоліо		
6	Огляд існуючих алгоритмів та систем	01.06.2025	виконано
	автоматизації портфоліо		
7	Розробка алгоритму створення інвестиційного	04.06.2025	виконано
	портфоліо		
8	Розробка веб-платформи для демонстрації	09.06.2025	виконано
	роботи алгоритму		
9	Написання пояснювальної записки	10.06.2025	виконано
10	Перевірка на академічний плагіат	12.06.2025	виконано
11	Нормоконтроль	13.06.2025	виконано
12	Підготовка презентації та доповіді	15.06.2025	виконано
13	Попередній захист	18.06.2025	виконано
14	Рецензування	19.06.2025	виконано
15	Захист перед ЕК	20.06.2025	

Дата видачі завдання 19 травня 20 25 р.

Здобувач _____
(підпис)

Керівник роботи _____ доц. Ігор Магдаліна
(підпис) (посада, власне ім’я, прізвище)

РЕФЕРАТ

Пояснювальна записка: 60 с., 17 рис., 1 табл., 1 дод., 20 джерел.

АЛГОРИТМІЧНІ ІНВЕСТИЦІЇ, ДИВЕРСИФІКАЦІЯ, ОПТИМІЗАЦІЯ ПОРТФОЛІО, РОЗПОДІЛ АКТИВІВ, ФІНАНСОВІ ЧАСОВІ РЯДИ, FINTECH, PYTHON.

Об’єкт дослідження – розробка алгоритму створення інвестиційних портфоліо на основі алгоритмів машинного навчання.

Предмет дослідження – дослідження алгоритмів машинного навчання та нейронних мереж для автоматизація створення портфоліо, методів та характеристик оцінки ефективності розробленого алгоритму та порівняння його із іншими публічними алгоритмами.

Мета роботи – створення алгоритму для автоматизації портфоліо із застосуванням методів машинного навчання та нейронних мереж, розробка користувацького інтерфейсу для спрощення взаємодії із розробленим алгоритмом.

Методи дослідження – теоретичний (збір та структуризація теоретичного матеріалу), експериментальний (програмна реалізація веб-додатку). Методи розробки базуються на мовах програмування Python та технологіях Tensorflow.

У ході виконання кваліфікаційної роботи розроблено алгоритм для автоматизації створення портфоліо, а також користувацький інтерфейс для спрощенної взаємодії із алгоритмом. Проведено оцінку ефективності розробленого алгоритму та порівняння із іншими відкритими алгоритмами, які мають схожу мету.

ABSTRACT

Bachelor’s thesis contains: 60 pp., 17 fig., 1 tabl., 1 ann., 20 references.

ALGORITHMIC INVESTMENTS, ASSET ALLOCATION, DIVERSIFICATION, FINANCIAL TIME SERIES, FINTECH, PORTFOLIO OPTIMIZATION, PYTHON.

The object of research is the development of an algorithm for creating investment portfolios based on machine learning algorithms.

The subject of research is the study of machine learning algorithms and neural networks for automating portfolio creation, methods and characteristics for evaluating the effectiveness of the developed algorithm, and comparing it with other public algorithms.

The purpose of the work is to create an algorithm for portfolio automation using machine learning methods and neural networks, and to develop a user interface to simplify interaction with the developed algorithm.

Research methods include theoretical (collection and structuring of theoretical material) and experimental (software implementation of a web application). Development methods are based on the Python programming language and Tensorflow technologies.

In the course of the qualification work, an algorithm for automating portfolio creation was developed, as well as a user interface for simplified interaction with the algorithm. The effectiveness of the developed algorithm was evaluated and compared with other open algorithms that have a similar purpose.

ЗМІСТ

Вступ 7
1 Аналіз та постановка задачі 10
1.1 Аналіз предметної галузі 10
1.1.1 Сучасна теорія портфоліо 10
1.1.2 Машинне навчання у фінансах 17
1.2 Постановка задачі 25
2 Огляд існуючих алгоритмів та систем автоматизації портфоліо 29
3 Розробка алгоритму створення інвестиційного портфоліо 37
4 Демонстрація роботи алгоритму на веб-платформі 47
Висновки 55
Перелік джерел посилання 57
Додаток А Відомість кваліфікаційної роботи 60

ВСТУП

Управління портфоліо являє собою стратегічний процес відбору, комбінування та нагляду за сукупністю інвестицій для досягнення конкретних фінансових цілей при одночасному управлінні ризиками. По суті, оптимізація портфоліо має на меті максимізувати дохідність при заданому рівні ризику або, навпаки, мінімізувати ризик при бажаному рівні дохідності. Цей тонкий баланс між ризиком і винагородою лежить в основі сучасної інвестиційної теорії та практики.

Важливість оптимізації портфоліо виходить за рамки простої максимізації прибутку. Ефективне управління портфоліо надає інвесторам кілька важливих переваг. По-перше, воно створює структурований підхід до збереження та примноження багатства, дозволяючи окремим особам та установам досягати фінансових цілей, починаючи від пенсійного забезпечення і закінчуючи примноженням капіталу. По-друге, вона привносить дисципліну в інвестиційний процес, зменшуючи емоційне прийняття рішень, яке часто призводить до неоптимальних результатів. По-третє, завдяки диверсифікації - стратегічному розподілу коштів між різними класами активів - оптимізація портфоліо допомагає пом'якшити вплив волатильності ринку на загальну ефективність інвестицій.

У сучасній фінансовій сфері, що характеризується зростаючою взаємозалежністю ринків та інформаційним перевантаженням, систематична оптимізація портфоліо набуває все більшого значення. Різниця між оптимальними та неоптимальними стратегіями розподілу активів може суттєво вплинути на довгострокові результати: дослідження Брінсона, Худа та Бібоуера (1986) свідчать, що рішення про розподіл активів пояснюють приблизно 90% коливань дохідності портфеля з плином часу.

Управління портфоліо зазнало значних трансформацій з моменту його формалізації в середині 20-го століття. Сучасний фундамент цієї галузі був закладений у 1952 році, коли Гаррі Марковіц опублікував свою

фундаментальну статтю «Портфоліо-вибір» в журналі «Journal of Finance», започаткувавши сучасну теорію портфоліо. Ця революційна концепція математично формалізувала ідею про те, що диверсифікація може зменшити ризик портфоліо, не обов'язково жертвуючи прибутковістю, і принесла Марковіцу Нобелівську премію з економіки в 1990 році.

Незважаючи на значний технологічний і теоретичний прогрес на сьогодні, автоматизовані інвестиційні стратегії стикаються з кількома суттєвими проблемами. По-перше, фінансові ринки демонструють нестаціонарну поведінку – моделі поведінки та взаємозв'язки, які були дійсними історично, можуть раптово змінитися або повністю зникнути. Ця тимчасова нестабільність створює труднощі для моделей машинного навчання, навчених на історичних даних, вимагаючи складних підходів для адаптації до мінливих ринкових умов.

По-друге, співвідношення сигнал/шум у фінансових даних залишається надзвичайно низьким. Рухи на ринку відбуваються під впливом незліченної кількості взаємодіючих факторів, багато з яких важко піддаються кількісній оцінці або прогнозуванню. Відокремлення значущих сигналів від випадкових коливань є постійним викликом для автоматизованих систем. Як зазначає Ло (2017) у своїй гіпотезі адаптивних ринків, фінансові ринки являють собою складні адаптивні системи, де традиційні припущення щодо ефективності можуть бути не зовсім правильними.

По-третє, автоматизовані стратегії повинні боротися з тим, що Де Прадо (2018) називає «прокляттям розмірності» фінансових даних. Широкий спектр потенційних ознак – від цінових моделей до макроекономічних показників та альтернативних джерел даних – створює обчислювальні труднощі у відборі ознак та зменшенні розмірності. Ця проблема стає особливо гострою при роботі з нейронними мережами, для ефективного навчання яких може знадобитися значний обсяг даних.

По-четверте, вплив на ринок і витрати на виконання представляють практичні обмеження. Теоретичний розподіл портфоліо, який виглядає оптимальним на папері, може виявитися неоптимальним, якщо врахувати транзакційні витрати, ліквідність ринку та вплив на ціни. Це вимагає складних алгоритмів виконання, які можуть мінімізувати ці ефекти, особливо для стратегій з частим перебалансуванням.

Нарешті, автоматизовані інвестиційні системи повинні враховувати регуляторні обмеження та етичні міркування. Оскільки алгоритми все частіше визначають інвестиційні рішення, питання прозорості, справедливості та системного ризику стають все більш важливими. Регуляторні рамки продовжують розвиватися у відповідь на ці технологічні зміни, створюючи динамічний ландшафт комплаєнсу.

Розробка алгоритму, який автоматизує формування портфоліо на основі інвестиційних категорій та уподобань користувача, як пропонується в цій кваліфікаційній роботі, має на меті вирішити деякі з цих проблем за допомогою методів машинного навчання. Порівнюючи різні методології та ретельно оцінюючи їх ефективність, це дослідження має на меті зробити внесок у постійну еволюцію підходів до оптимізації портфеля в умовах дедалі складнішого фінансового ландшафту.

1 АНАЛІЗ ТА ПОСТАНОВКА ЗАДАЧІ

1.1 Аналіз предметної галузі

1.1.1 Сучасна теорія портфоліо

Сучасна теорія портфоліо з'явилася як новаторська концепція, коли Гаррі Марковіц представив її у своїй статті «Вибір портфоліо» в журналі «Journal of Finance» у 1952 році [1]. Цей математичний підхід перетворив управління інвестиціями з мистецтва на науку, формалізувавши взаємозв'язок між ризиком та дохідністю.

В основі внеску Марковіца лежить концепція ефективної межі, графічне зображення оптимальних портфоліо, які пропонують найвищу очікувану дохідність за певного рівня ризику, або, навпаки, найнижчий ризик за заданого рівня очікуваної дохідності. Марковіц продемонстрував, що ризик портфоліо не можна оцінити, просто розглядаючи окремі активи ізольовано; скоріше, кореляції між активами фундаментально визначають поведінку портфеля.

Математично Марковіц виразив дохідність портфоліо як зважену суму дохідностей окремих активів. Таке відношення можна записати у вигляді формули 1.1.

$$E(R_p) = \sum w_i \ E(R_i), \tag{1.1}$$

де $E(R_p)$ – очікувана дохідність портфоліо;

$E(R_i)$ – очікувана дохідність активу i.

Ризик портфоліо, вимірюваний дисперсією, включає не лише волатильність окремих активів, але й їх коваріації. Його можна виразити у вигляді наступної формули 1.2.

$$\sigma_p^2 = \sum_i \sum_j w_i w_j \sigma_{ij}, \quad (1.2)$$

де σ_p^2 – дисперсія портфоліо;

w_i та w_j – ваги активів i та j;

σ_{ij} – коваріація між доходами активів i та j;

Мінімізувавши це дисперсійне рівняння для кожного рівня очікуваної дохідності, Марковіц продемонстрував, як математично визначити ефективну межу. Це відкриття показало, що диверсифікація може зменшити ризик портфоліо, не обов'язково жертвуючи очікуваною прибутковістю – принцип, який трансформував інвестиційну практику.

Спираючись на концепцію Марковіца, Вільям Шарп, Джон Лінтнер та Ян Моссін незалежно один від одного розробили Модель оцінки капітальних активів (CAPM), яка ще більше поглибила розуміння взаємозв'язку між ризиком та дохідністю. CAPM запровадила відмінність між систематичним ризиком (ринковим ризиком, який неможливо диверсифікувати) та несистематичним ризиком (специфічним ризиком компанії, який можна усунути шляхом диверсифікації).

CAPM надає простий метод визначення очікуваної дохідності активу на основі його схильності до систематичного ризику та виражається у вигляді наступної формули 1.3.

$$E(R_i) = R_f + \beta_i\left[E(R_m) - R_f\right], \quad (1.3)$$

де $E(R_i)$ – очікувана дохідність активу i;

R_f – безризикова ставка;

β_i – чутливість активу до ринкових змін;

$E(R_m)$ – очікувана ринкова дохідність;

$\left[E(R_m) - R_f\right]$ – премія за ринковий ризик.

Показник чутливості активу, наріжний камінь CAPM, кількісно вимірює систематичний ризик активу відносно ринку. Активи з $\beta > 1$ демонструють більшу волатильність, ніж ринок, тоді як активи з $\beta < 1$ демонструють меншу волатильність. Таким чином, CAPM встановив лінійний зв'язок між систематичним ризиком та очікуваною дохідністю, забезпечивши теоретичний орієнтир для оцінки ефективності інвестицій.

Модель також запровадила лінію ринку капіталу (CML), яка представляє оптимальні комбінації безризикового активу та ринкового портфоліо. Ця концепція ще більше підвищила ефективність диверсифікації та забезпечила основу для побудови портфоліо.

Фундаментальне протиріччя між ризиком і дохідністю є, мабуть, найбільш стійким принципом у фінансах. MPT формалізувала цей взаємозв'язок за допомогою кількісних методів, продемонструвавши, що раціональні інвестори повинні вимагати додаткового очікуваного доходу за прийняття додаткового ризику.

Цей взаємозв'язок зазвичай характеризується наступним особливостями:

– вимірювання ризику;

– вимірювання прибутковості;

– ефективність, скоригована на ризик.

Стандартне відхилення прибутковості (σ) слугує основним показником загального ризику в MPT, хоча в останні десятиліття набули популярності альтернативні показники, такі як Value-at-Risk (VaR) та умовна вартість під ризиком (CVaR).

Очікувана дохідність зазвичай визначається на основі історичних даних або прогнозних моделей, які враховують фундаментальні та ринкові фактори.

Такі показники, як коефіцієнт Шарпа (надлишкова дохідність на одиницю ризику), стали стандартними для оцінки ефективності інвестицій і розраховуються за допомогою наступної формули 1.4.

$$\text{Sharpe Ratio} = \frac{R_p - R_f}{\sigma_p}. \quad (1.4)$$

де R_p – дохідність портфоліо;

R_f – безризикова ставка;

σ_p – стандартне відхилення портфоліо.

Яскравим прикладом застосування коефіцієнт Шарпа можна вважати метод формування оптимального портфоліо, запропонованого Марковітцом, в основі якого лежить визначення ефективного кордону, що зображений на рисунку 1.1.

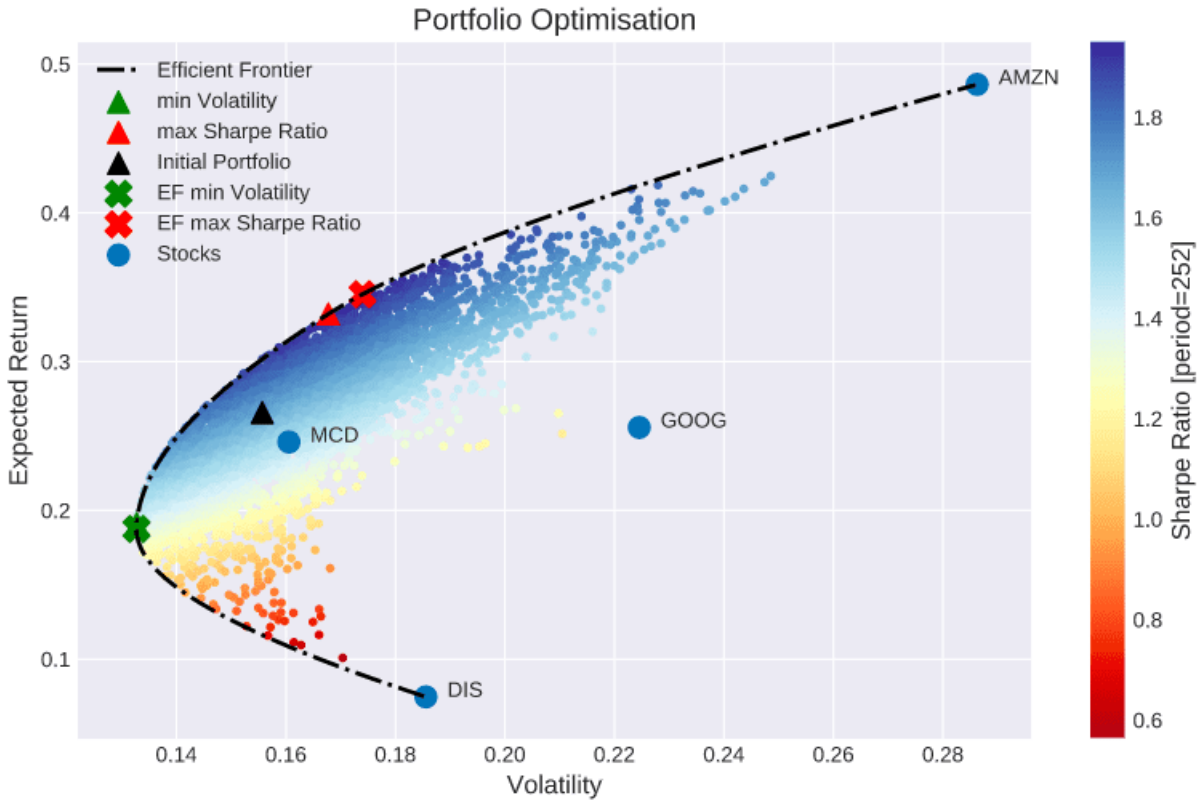

Рисунок 1.1 – Приклад застосування коефіцієнту Шарпа під час визначення оптимального портфоліо

MPT докорінно змінила уявлення інвесторів про компроміс між ризиком і прибутковістю, продемонструвавши, що математична оптимізація

може покращити цей баланс, виходячи за рамки інтуїтивних підходів. За допомогою кількісних методів інвестори можуть визначити можливості для підвищення дохідності без пропорційного збільшення ризику або для зменшення ризику без шкоди для очікуваної дохідності.

Диверсифікація – яку часто називають «єдиним безкоштовним обідом у фінансах» – є одним з найбільш практичних висновків МРТ. Теорія математично продемонструвала, що поєднання активів з недосконалою кореляцією може зменшити волатильність портфоліо нижче середньозваженого значення волатильності окремих активів. Переваги диверсифікації для зниження ризиків зростають зі зменшенням кореляції між активами, причому найбільшу користь від диверсифікації приносять негативно корельовані активи, хоча на фінансових ринках такі взаємозв'язки зустрічаються відносно рідко. Дослідження Еванса та Арчера показало, що більша частина переваг диверсифікації досягається за допомогою відносно невеликої кількості цінних паперів, як правило, близько 20–30 акцій, після чого додаткова диверсифікація дає лише незначне зниження ризику. Цей феномен спадаючої віддачі від диверсифікації має важливі наслідки для формування портфоліо, вказуючи на те, що якість диверсифікації часто має більше значення, ніж кількість.

Ефективна диверсифікація виходить за рамки акцій і включає різні класи активів, такі як облігації, товари та нерухомість, які по-різному реагують на економічні фактори. Цей принцип перехресної диверсифікації активів лежить в основі сучасних стратегій розподілу активів і забезпечує захист від ризиків, які можуть одночасно вплинути на всі акції. Аналогічно, глобальні інвестиції розширюють можливості для диверсифікації, особливо коли внутрішні та міжнародні ринки демонструють нижчу кореляцію. Однак зростаюча інтеграція світових ринків в останні десятиліття дещо зменшила ці переваги, оскільки фінансова інфекція може легше поширюватися через кордони під час кризових періодів. Сучасна теорія портфоліо ще більше розширила диверсифікацію за межі традиційних

класів активів до базових факторів ризику, прагнучи збалансувати вплив на джерела систематичного ризику, такі як вартість, динаміка та волатильність. Цей факторний підхід визнає, що, здавалося б, різні активи можуть мати спільні ризики. Важливо, що МРТ продемонстрував, що оптимальна диверсифікація досягається не шляхом простого володіння великою кількістю активів, а шляхом стратегічного поєднання активів із взаємодоповнюючими характеристиками ризику – розуміння, яке залишається фундаментальним для сучасної побудови портфоліо.

Незважаючи на свій революційний вплив, сучасна теорія портфоліо містить припущення та спрощення, які обмежують її практичне застосування. Розуміння цих обмежень є важливим для розробки вдосконалених підходів з використанням методів машинного навчання. Суттєвим обмеженням є припущення МРТ про те, що дохідність активів має нормальний розподіл, що суперечить емпіричним даним, які показують, що фінансові прибутки зазвичай мають «жирні хвости» (надлишковий ексцес) та від'ємну асиметрію. Таке припущення про нормальний розподіл може значно недооцінювати події з екстремальним ризиком, залишаючи портфоліо вразливими до подій «чорного лебедя», які традиційна оптимізація вважає статистично малоймовірними. Традиційна оптимізація також розглядає кореляції як фіксовані параметри, тоді як фактичні ринкові кореляції демонструють значну нестабільність. Ця проблема стає особливо гострою під час кризових періодів, коли кореляції часто зростають саме тоді, коли переваги диверсифікації є найбільш необхідними – явище, яке учасники ринку барвисто описують як «всі кореляції прямують до однієї» під час ринкових крахів.

Модель Марковіца пропонує рішення для одного періоду, яке не враховує багатоперіодну природу інвестиційних рішень. Це обмеження нехтує важливими міркуваннями, включаючи трансакційні витрати на відновлення балансу та залежність результатів інвестицій від шляху, де послідовність прибутків може суттєво вплинути на кінцевий добробут.

Оптимізація за середньою дисперсією, як відомо, також є чутливою до вхідних параметрів, оскільки невеликі зміни в очікуваних доходах можуть призвести до кардинально різних розподілів портфоліо. Ця властивість «максимізації помилки», відзначена Мішо, часто призводить до екстремальних розподілів, які виглядають теоретично оптимальними, але погано працюють поза вибіркою. Стандартне відхилення як міра ризику має ще одне обмеження, оскільки воно однаково карає волатильність як в бік зростання, так і в бік падіння, хоча інвестори зазвичай бояться втрат більше, ніж цінують еквівалентні прибутки. Альтернативні міри ризику, такі як відхилення в бік зниження та максимальна просадка, можуть краще відповідати уподобанням інвесторів, особливо для асиметричного розподілу доходу.

Традиційна оптимізація також нехтує поведінковими аспектами інвестування, включаючи неприйняття втрат, ментальну бухгалтерію та інші когнітивні упередження, задокументовані поведінковою економікою. Ці психологічні фактори можуть суттєво впливати на рішення інвесторів та їхню задоволеність, потенційно спричиняючи відмову від надійних інвестиційних стратегій у періоди низької ефективності. Нарешті, класична оптимізація не враховує ціновий вплив змін у портфоліо, який може бути суттєвим для великих портфелів або менш ліквідних активів. Ці різноманітні обмеження стимулювали численні розширення оригінальної системи, включаючи моделі Блека-Літтермана, факторні підходи та надійні методи оптимізації. Зовсім недавно методи машинного навчання з'явилися як перспективні інструменти для вирішення деяких з цих проблем завдяки їх здатності враховувати нелінійні взаємозв'язки, адаптуватися до мінливих ринкових умов і включати альтернативні джерела даних – можливості, які роблять їх особливо актуальними для автоматизованої системи генерації портфоліо, запропонованої в цій кваліфікаційній роботі.

1.1.2 Машинне навчання у фінансах

Застосування машинного навчання на фінансових ринках зазнало значної еволюції за останні кілька десятиліть, перетворившись з експериментальних академічних досліджень на поширену практику серед провідних фінансових установ. Перші застосування в 1990-х роках були зосереджені на відносно простих завданнях розпізнавання образів, таких як використання нейронних мереж для прогнозування руху цін на акції на основі технічних індикаторів. Ці перші спроби, хоча й були новаторськими, часто страждали від надмірної пристосованості і демонстрували обмежену практичну цінність за межами контрольованих дослідницьких середовищ.

На початку 2000-х років відбувся поступовий зсув у міру зростання обчислювальних потужностей і появи більш досконалих алгоритмів. Машини опорних векторів (SVM) та дерева рішень стали популярними для кредитного скорингу та виявлення шахрайства – сфер, де проблеми бінарної класифікації добре узгоджувалися з сильними сторонами цих алгоритмів. Однак світова фінансова криза 2008 року стала переломним моментом для кількісних підходів у фінансах. Обмеження традиційних моделей ризику стали до болю очевидними, що викликало новий інтерес до більш адаптивних методологій, здатних враховувати нелінійні взаємозв'язки та екстремальні події.

2010-ті роки ознаменувалися тим, що Хітон називає «революцією глибокого навчання у фінансах», яка характеризується поєднанням трьох важливих факторів:експоненціальним зростанням обчислювальних потужностей, доступністю величезних масивів фінансових даних та значними алгоритмічними проривами. Фінансові установи почали впроваджувати моделі глибокого навчання для широкого спектру застосувань – від алгоритмів високочастотної торгівлі до оцінки кредитних ризиків та аналізу настроїв у фінансових новинах. Система LOXM від J.P. Morgan, представлена у 2017 році, стала прикладом цієї тенденції,

використовуючи навчання з підкріпленням для оптимізації виконання торгових операцій, продемонструвавши потенціал ML для вирішення складних, багатовимірних фінансових проблем.

Останні розробки характеризуються зростаючою складністю як в архітектурі моделей, так і у використанні даних. Сучасні програми інтегрують структуровані фінансові дані з альтернативними джерелами, включаючи супутникові знімки, схеми мобільних платежів і обробку природної мови дзвінків з повідомленнями про прибутки. Такі фірми, як Two Sigma, Renaissance Technologies та AQR Capital Management, створили значні конкурентні переваги завдяки своїм можливостям машинного навчання, хоча запатентований характер їхніх конкретних реалізацій обмежує академічне вивчення їхніх підходів.

Протягом усієї цієї еволюції фінансова індустрія зберігала прагматичну позицію щодо впровадження ML, балансуючи між алгоритмічними інноваціями та практичними вимогами пояснюваності, дотримання регуляторних норм та управління ризиками. Ця суперечність продовжує впливати на те, як методи машинного навчання розгортаються у виробничих середовищах.

Оптимізація портфоліо представляє окремі проблеми, які можна вирішити за допомогою різних парадигм машинного навчання, кожна з яких пропонує унікальні переваги та обмеження. Підходи керованого навчання покладаються на позначені історичні дані для навчання моделей, які можуть передбачити майбутні показники ефективності. У контексті портфоліо ці реалізації зазвичай зосереджуються на прогнозуванні очікуваної прибутковості, волатильності або показників ефективності, скоригованих на ризик, таких як коефіцієнт Шарпа. Наприклад, Гу, Келлі та Сю продемонстрували, що методи керованого навчання, зокрема ансамблеві моделі, такі як випадкові ліси та нейронні мережі, можуть значно перевершити традиційні факторні моделі у прогнозуванні перехресних доходностей акцій.

Основна перевага керованих підходів полягає в тому, що вони безпосередньо узгоджуються з цілями портфоліо – вони явно оптимізують метрики, найбільш релевантні для інвестиційної ефективності. Однак вони стикаються зі значними проблемами, включаючи шум позначень (фінансові прибутки за своєю природою є зашумленими), нестаціонарність (зв'язки між характеристиками та прибутковістю змінюються з часом) та ризик надмірного пристосування до історичних моделей, які можуть не зберегтися. Більше того, дефіцит фінансових даних порівняно зі складністю ринкової динаміки створює те, що Де Прадо називає «прокляттям розмірності» у фінансових додатках.

Неконтрольоване навчання пропонує додатковий підхід, визначаючи внутрішні закономірності у фінансових даних, не покладаючись на явні показники ефективності. Ці методи чудово справляються зі зменшенням розмірності, виявленням режимів та ідентифікацією аномалій. Для побудови портфоліо алгоритми кластеризації можуть ідентифікувати групи активів зі схожими характеристиками ризику, що потенційно покращує диверсифікацію за межами традиційних класів активів. Аналіз головних компонент (PCA) та автокодери виявилися особливо цінними для вилучення латентних факторів з багатовимірних фінансових даних, а Лопес де Прадо продемонстрував їхню ефективність у створенні більш стабільних кореляційних матриць для оптимізації портфоліо.

Найдосконаліші системи оптимізації портфоліо часто поєднують обидві парадигми в багатоетапному процесі. Неконтрольовані методи можуть спочатку визначати ринкові режими або зменшувати розмірність ознак, після чого застосовуються контрольовані методи, які використовують ці знання для прийняття конкретних рішень щодо розподілу коштів. Такий гібридний підхід визнає взаємодоповнюючі сильні сторони кожної методології, водночас пом'якшуючи їхні індивідуальні обмеження.

Нейронні мережі пропонують особливо переконливі переваги для фінансового прогнозування завдяки своїй здатності вловлювати складні нелінійні взаємозв'язки, не вимагаючи явної специфікації функціональних форм. Кілька архітектур продемонстрували особливу актуальність для задач оптимізації портфоліо.

Багатошарові персептрони (MLP), найфундаментальніша архітектура нейронної мережі, показали дивовижну ефективність для прогнозування перехресної дохідності. Незважаючи на свою концептуальну простоту, MLP можуть апроксимувати як завгодно складні функції за наявності достатньої кількості прихованих шарів і нейронів. Гу продемонстрував, що навіть відносно неглибокі MLP можуть перевершити традиційні факторні моделі та альтернативні підходи машинного навчання при прогнозуванні прибутковості акцій. Однак їхня ефективність знижується при обробці послідовних фінансових даних, де часові залежності відіграють вирішальну роль.

Згорткові нейронні мережі (CNN), хоча спочатку були розроблені для обробки зображень, знайшли несподіване застосування у фінансах завдяки своїй здатності виявляти локальні закономірності в різних часових масштабах. Замість того, щоб обробляти зображення, ШНМ у фінансах зазвичай працюють з перетвореними ціновими даними, де «фільтри» вчаться розпізнавати технічні закономірності за різні ретроспективні періоди. Сезер та Озбайоглу продемонстрували ефективність ШНМ для прогнозування цінових трендів шляхом перетворення цінових послідовностей у зображення, які відображають локальні часові залежності.

Рекурентні нейронні мережі (RNN), зокрема їхні варіанти з довгою короткочасною пам'яттю (LSTM) та закритими рекурентними блоками (GRU), долають часові обмеження MLP, підтримуючи внутрішній стан, який фіксує послідовні залежності. Ця архітектура природно узгоджується з природою часових рядів фінансових даних. Фішер і Краусс показали, що мережі LSTM можуть генерувати значні надлишкові прибутки

в акціях S&P 500, перевершуючи випадкові ліси, глибокі нейронні мережі та базові лінії логістичної регресії. LSTM чудово вловлюють як короткострокові, так і довгострокові залежності у фінансових часових рядах, що робить їх особливо придатними для завдань, де минула інформація суттєво впливає на майбутні результати.

Зовсім недавно архітектури, що базуються на увазі, в тому числі трансформери, почали проникати у фінансові додатки. Ці моделі, які підкреслюють відносну важливість різних вхідних характеристик або часових періодів, продемонстрували багатообіцяючу здатність відображати складні залежності між різними активами та часовими горизонтами. Чен продемонстрував, що механізми самонавчання можуть покращити ефективність портфоліо, динамічно коригуючи релевантність історичних спостережень на основі поточних ринкових умов.

На практиці архітектури нейронних мереж для фінансового прогнозування часто включають специфічні для конкретної галузі адаптації, щоб врахувати особливості ринкових даних. До них відносяться індивідуальні методи регуляризації для боротьби з надмірним пристосуванням до обмежених фінансових даних, механізми, що враховують неоднакову важливість недавньої та віддаленої ринкової історії, а також спеціалізовані функції втрат, які більш точно відповідають інвестиційним цілям, ніж стандартні статистичні показники.

Навчання з підкріпленням (RL) пропонує особливо привабливу основу для управління портфоліо, безпосередньо оптимізуючи інвестиційні рішення на основі їхніх довгострокових наслідків, а не покладаючись на проміжні кроки прогнозування. Цей підхід моделює управління портфоліо як послідовний процес прийняття рішень, де агент (портфельний менеджер) взаємодіє з навколишнім середовищем (ринком), здійснюючи дії (розподіл портфеля) для максимізації кумулятивної винагороди (дохідності, скоригованої на ризик). Цей процес можна представити у вигляді рисунку 1.2.

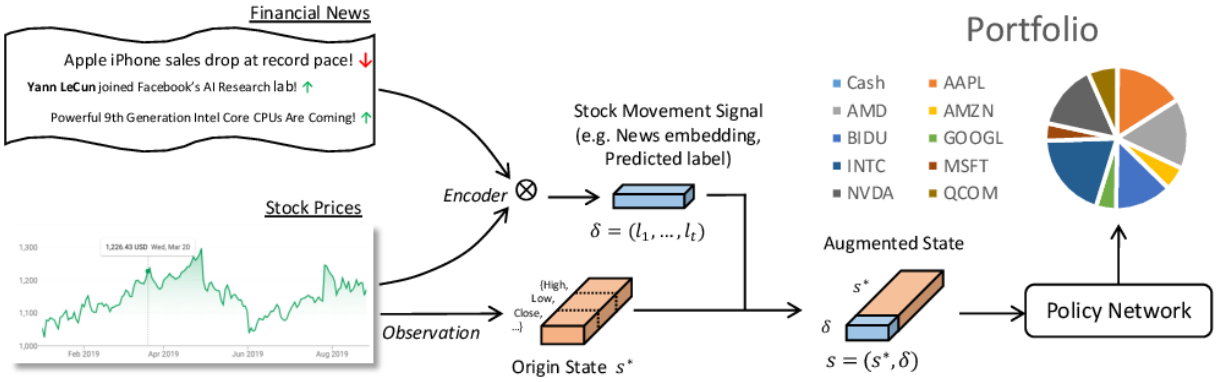

Рисунок 1.2 – Приклад використання навчання з підкріпленням в управлінні портфоліо

Формулювання RL природно узгоджується з кількома викликами в оптимізації портфоліо. По-перше, вона визнає послідовний характер інвестиційних рішень, де поточні розподіли впливають на майбутні можливості через реалізовані прибутки і трансакційні витрати. По-друге, вона може включати декілька цілей одночасно, балансуючи між максимізацією прибутку та обмеженнями ризику і торговими витратами. По-третє, агенти RL можуть адаптуватися до мінливих ринкових умов, постійно оновлюючи свою політику на основі спостережуваних результатів, потенційно вирішуючи проблему нестаціонарності, яка є характерною для багатьох моделей фінансового прогнозування.

Кілька ключових подій прискорили впровадження RL в портфоліо-менеджменті. Цзян вперше застосував глибоке навчання з підкріпленням для розподілу портфоліо, продемонструвавши, що їхній підхід може перевершити традиційні методи при тестуванні на криптовалютних ринках. Їхній підхід, що отримав назву Deep Deterministic Policy Gradient (DDPG), розглядає ваги портфоліо як безперервні дії і навчається оптимальній політиці розподілу через пряму взаємодію з ринковими даними. Алгоритм представлений на рисунку 1.3.

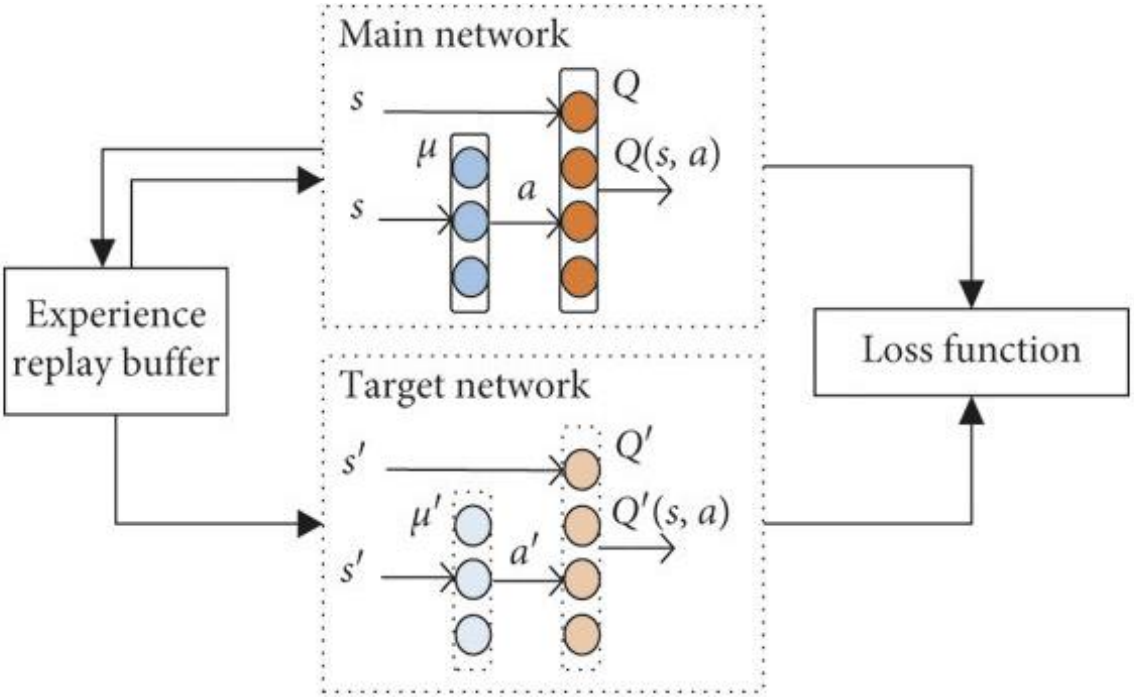

Рисунок 1.3 – Алгоритм DDPG

Ця рання робота довела життєздатність RL для завдань портфоліо, але висвітлила проблеми з побудовою реалістичних середовищ моделювання.

Пізніші підходи усунули ці обмеження завдяки вдосконаленому дизайну середовища. Йе розробив ринковий симулятор, що включає транзакційні витрати, вплив на ринок та обмеження ліквідності, щоб забезпечити більш реалістичні умови навчання для агентів. Їхні результати продемонстрували, що агенти, навчені в цих покращених середовищах, показали значно кращі результати поза вибіркою порівняно з тими, хто навчався в ідеалізованих умовах, що свідчить про те, що точність середовища відіграє вирішальну роль у практичному застосуванні RL.

Кілька варіантів RL показали особливу перспективність для додатків портфоліо. Проксимальна оптимізація політики (Proximal Policy Optimization, PPO), запропонована Шульманом, набула популярності у фінансових додатках завдяки своїй вибірковій ефективності та стабільності. Адаптивні стратегії, такі як метанавчання з підкріпленням, дозволяють агентам швидко адаптуватися до мінливих ринкових режимів, навчаючись

вчитися на обмеженому досвіді. Ця здатність вирішує проблему нестаціонарності ринку, яка підриває багато традиційних підходів.

Незважаючи на ці досягнення, навчання з підкріпленням для управління портфоліо стикається зі значними проблемами. Компроміс між розвідкою та експлуатацією стає особливо гострим у фінансовому контексті, коли розвідка пов'язана з реальними витратами. Ефективність вибірки залишається критично важливою з огляду на обмеженість історичних даних, доступних для рідкісних ринкових умов.

Можливо, найголовніша проблема полягає в тому, що стохастична і нестаціонарна природа фінансових ринків ускладнює розробку моделюючих середовищ, які б адекватно готували агентів до майбутніх ринкових умов.

Сучасні дослідження вирішують ці проблеми за допомогою декількох перспективних напрямків.

Мультиагентні середовища RL моделюють динаміку ринку як таку, що виникає в результаті взаємодії декількох агентів з різними цілями, що потенційно створює більш реалістичні симуляції.

Гібридні підходи поєднують RL з керованим навчанням, використовуючи моделі прогнозування для підвищення достовірності середовища.

Пояснювальні методи RL спрямовані на те, щоб зробити рішення агентів більш прозорими, вирішуючи проблеми «чорного ящика», які обмежують інституційне впровадження алгоритмічних підходів.

Оскільки обчислювальні можливості продовжують розвиватися, а набори фінансових даних розширюються, підходи навчання з підкріпленням, ймовірно, будуть відігравати все більш важливу роль в автоматизованих системах управління портфелем, особливо для додатків, подібних до запропонованого в цій кваліфікаційній роботі, де різні інвестиційні категорії та часові горизонти вимагають адаптивних стратегій розподілу, які збалансовують кілька цілей.

1.2 Постановка задачі

Оптимізація портфоліо залишається однією з найскладніших проблем у фінансових технологіях, оскільки знаходиться на перетині фінансів, математики, інформатики та поведінкової економіки. Незважаючи на значні теоретичні досягнення з часу фундаментальної роботи Марковіца, практична реалізація оптимізації портфоліо продовжує стикатися з істотними проблемами в реальних умовах. Традиційні підходи, як правило, вимагають великого фінансового досвіду, значних витрат часу та спеціалізованих знань, що створює значні бар'єри для індивідуальних інвесторів. Тим часом, експоненціальне зростання доступних фінансових даних у поєднанні з дедалі складнішою ринковою динамікою робить ручне формування портфоліо все менш оптимальним порівняно з алгоритмічними альтернативами.

Швидкий розвиток технологій машинного навчання та штучного інтелекту пропонує нові перспективні шляхи для вирішення цих давніх проблем. Нейронні мережі, зокрема, демонструють значний потенціал для виявлення складних нелінійних взаємозв'язків у фінансових даних, які традиційні моделі часто пропускають. Однак подолання розриву між теоретичними можливостями машинного навчання та практичними, зручними для користувача інвестиційними інструментами вимагає ретельного розгляду як технічних проблем реалізації, так і реальних потреб користувачів.

Це дослідження спрямоване на задоволення гострої потреби в доступних автоматизованих системах оптимізації портфоліо, які можуть демократизувати складні інвестиційні стратегії, зберігаючи при цьому стійкість до різноманітних ринкових умов. Розробляючи алгоритм, який перетворює вподобання користувачів на оптимізовані портфоліо за допомогою нейромережевих методологій, ця робота має на меті зробити внесок у постійну трансформацію управління інвестиціями з процесу, що

залежить від досвіду, на технологічну послугу, доступну для широких верств населення.

Основною проблемою, що розглядається в даній кваліфікаційній роботі, є розробка автоматизованого алгоритму, який генерує оптимізовані інвестиційні портфоліо на основі мінімальних вхідних даних користувача щодо вподобань щодо ризику, інвестиційних горизонтів та фінансових цілей. Зокрема, алгоритм повинен перетворити спрощені вхідні дані користувача, включаючи категорію інвестицій (перспективні, високопотенційні або стабільні) та тривалість інвестицій (коротко-, середньо- або довгострокові), у комплексний розподіл портфоліо, який оптимізує профіль ризику та дохідності відповідно до цих уподобань.

Це завдання охоплює кілька взаємопов'язаних викликів:

– перетворення якісних уподобань користувачів у кількісні інвестиційні параметри, які можуть бути використані для прийняття алгоритмічних рішень;

– впровадження архітектур нейронних мереж, здатних ідентифікувати активи, які відповідають визначеним інвестиційним категоріям на основі історичних показників та фундаментальних характеристик;

– балансування між кількома конкуруючими цілями, включаючи очікувану прибутковість, мінімізацію ризиків та відповідність інвестиційним горизонтам, визначеним користувачем;

– забезпечення стійкості алгоритму в різних ринкових умовах, особливо під час зміни режимів та стресових сценаріїв на ринку;

– розробка системи, здатної до безперервного навчання та адаптації в міру надходження нових ринкових даних;

– створення алгоритму, який максимізує доступність за рахунок мінімального вкладу користувача, зберігаючи при цьому достатню складність підходу до оптимізації, що лежить в її основі.

Основна гіпотеза цього дослідження полягає в тому, що методології нейронних мереж, належним чином впроваджені та навчені на повних

наборах фінансових даних, можуть перевершити традиційні підходи до оптимізації портфоліо, вимагаючи при цьому значно меншого технічного досвіду від кінцевих користувачів.

Для успішного вирішення поставленої задачі алгоритм автоматизованого формування портфоліо повинен відповідати наступним функціональним та технічним вимогам.

Алгоритм повинен перетворити три обрані користувачем категорії інвестицій (перспективні, високопотенційні та стабільні) у кількісні інвестиційні критерії, які можна виміряти. Перспективні інвестиції повинні зосереджуватися на активах, що позиціонуються для сталого довгострокового зростання, інвестиції з високим потенціалом повинні визначати можливості з очікуваною прибутковістю вище середнього, незважаючи на вищий ризик, а стабільні інвестиції повинні надавати пріоритет мінімальній волатильності та збереженню капіталу.

Система повинна оптимізуватися по-різному залежно від обраної тривалості інвестицій (коротко-, середньо- або довгострокової), відповідно коригуючи толерантність до ризику, частоту ребалансування та критерії вибору активів відповідно до часових інвестиційних цілей. Середньо- та довгострокові варіанти повинні включати додаткову складність для преміум-користувачів.

Основний інтерфейс повинен вимагати лише вибору категорії та суми інвестицій, перетворюючи ці обмежені вхідні дані на комплексний розподіл портфоліо, не вимагаючи від користувачів технічних фінансових знань.

Хоча методологія, що лежить в основі, може використовувати складні архітектури нейронних мереж, система повинна представляти результати в доступному форматі, чітко повідомляючи про очікувані характеристики співвідношення ризиків і прибутковості та відповідність до обраної інвестиційної категорії.

Алгоритм повинен включати в себе механізми адаптації до мінливих ринкових умов, в тому числі процедури ребалансування рекомендацій і реагування на значні ринкові події або зміни режимів.

Враховуючи ці вимоги, це дослідження має на меті розробити практичну, доступну та надійну автоматизовану систему оптимізації портфоліо, яка використовує можливості нейронних мереж, зберігаючи при цьому зручність використання для інвесторів з обмеженими фінансовими знаннями. Успішна реалізація такої системи стане значним внеском у постійну демократизацію складних інвестиційних стратегій за допомогою технологічних інновацій.

2 ОГЛЯД ІСНУЮЧИХ АЛГОРИТМІВ ТА СИСТЕМ АВТОМАТИЗАЦІЇ ПОРТФОЛІО

Протягом останнього десятиліття на сферу автоматизованого управління портфоліо значний вплив справила поява платформ робо-консультантів. Ці системи є першою спробою спростити складну оптимізацію портфоліо за допомогою алгоритмічних підходів, хоча вони, як правило, спираються на традиційну фінансову теорію, а не на передові методи машинного навчання.

Betterment і Wealthfront є піонерами серед робо-консультантів, які використовують сучасну теорію портфоліо та оптимізацію середнього відхилення як основні методології. Інтерфейс дашборду платформи Betterment представлено на рисунку 2.1.

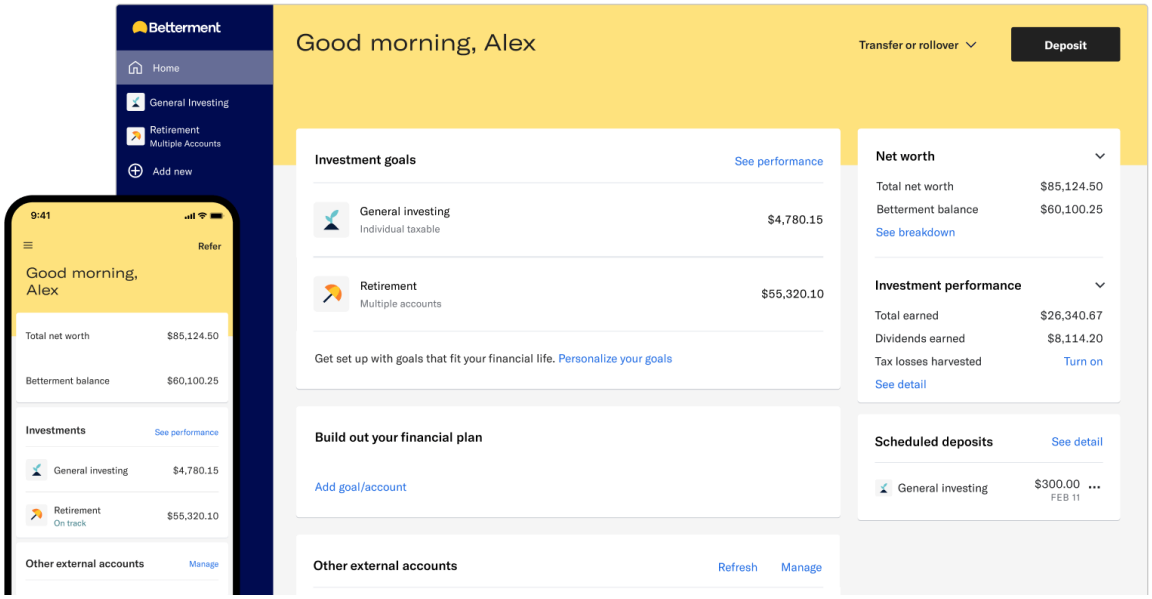

Рисунок 2.1 – Інтерфейс дашборду платформи Betterment

Ці платформи автоматизують побудову портфоліо, збираючи базову інформацію про користувачів за допомогою анкет, що оцінюють толерантність до ризику, терміни інвестування та фінансові цілі. Потім

системи відображають ці дані на заздалегідь визначених моделях розподілу активів, зазвичай використовуючи недорогі ETF, що охоплюють внутрішні та міжнародні ринки акцій, цінні папери з фіксованим доходом та альтернативні інвестиції. Обидві платформи включають функції автоматичного перебалансування, податкового збитку та інвестування на основі цілей, які коригують розподіл на основі конкретних фінансових цілей, таких як вихід на пенсію або придбання житла.

Основні переваги цих усталених платформ включають їх простоту, відповідність нормативним вимогам та перевірену репутацію серед мільйонів користувачів. Вони успішно усувають багато перешкод для складного управління портфоліо для індивідуальних інвесторів, пропонуючи диверсифікацію професійного рівня та оптимізацію податків за відносно низькими витратами. Однак їх залежність від традиційних методів оптимізації обмежує їх здатність адаптуватися до мінливих ринкових умов. Підхід на основі анкет, хоча і є зручним для користувачів, часто надмірно спрощує складні уподобання інвесторів і може не враховувати нюанси ставлення до ризику або еволюцію інвестиційних філософій.

Schwab Intelligent Portfolios та Vanguard Personal Advisor Services представляють гібридні підходи, що поєднують алгоритмічне формування портфоліо з людським наглядом. Ці платформи використовують масштаб та досвід усталених фінансових установ, зберігаючи при цьому автоматизовану основну функціональність. Підхід Schwab наголошує на ширшій диверсифікації між класами активів, включаючи товари та інвестиційні фонди нерухомості, тоді як Vanguard інтегрує людських радників для рахунків з більшим балансом. Інституційна підтримка забезпечує підвищену надійність та регуляторний нагляд, хоча вона також може обмежувати інновації в алгоритмічних підходах.

Інтерфейс дашборду сервісу Schwab Intelligent Portfolios представлений на рисунку 2.2.

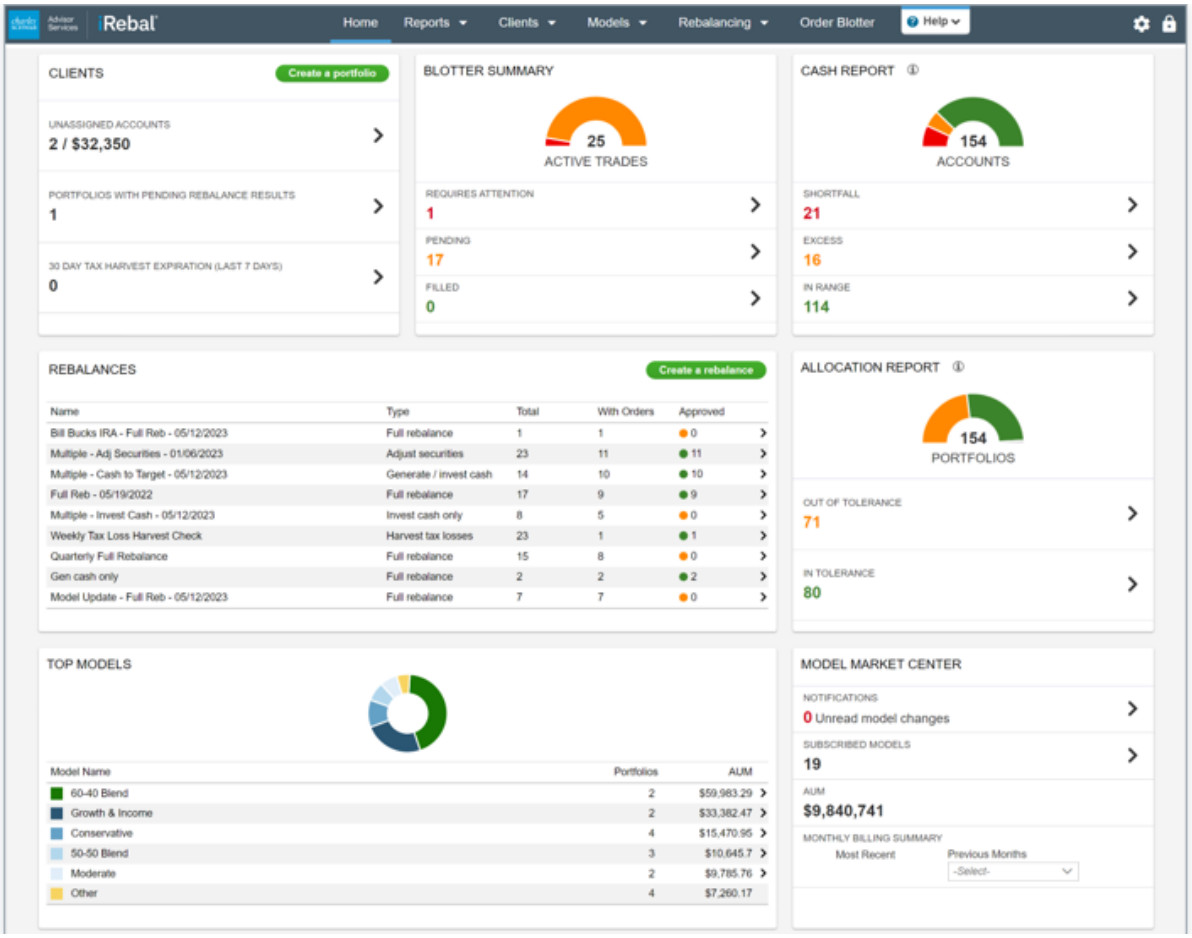

Рисунок 2.2 – Інтерфейс дашборду Schwab Intelligent Portfolios

Нове покоління платформ почало використовувати більш досконалі технології штучного інтелекту та машинного навчання, відходячи від традиційної оптимізації середнього значення та дисперсії на користь адаптивних алгоритмічних підходів.

Wealthsimple інтегрувала компоненти машинного навчання в процес оптимізації свого портфоліо, зокрема для оцінки ризиків та прийняття рішень щодо динамічного перебалансування. Їхня система аналізує ринкові умови та результати окремих рахунків для коригування термінів та обсягів розподілу, що є еволюцією від статичних модельних портфоліо. Платформа підтримує зручні для користувача інтерфейси, одночасно інтегруючи більш складні аналітичні інструменти, включаючи аналіз настроїв на ринку та

альтернативні джерела даних. Інтерфейс дашборду цієї платформи наведено на рисунку 2.3.

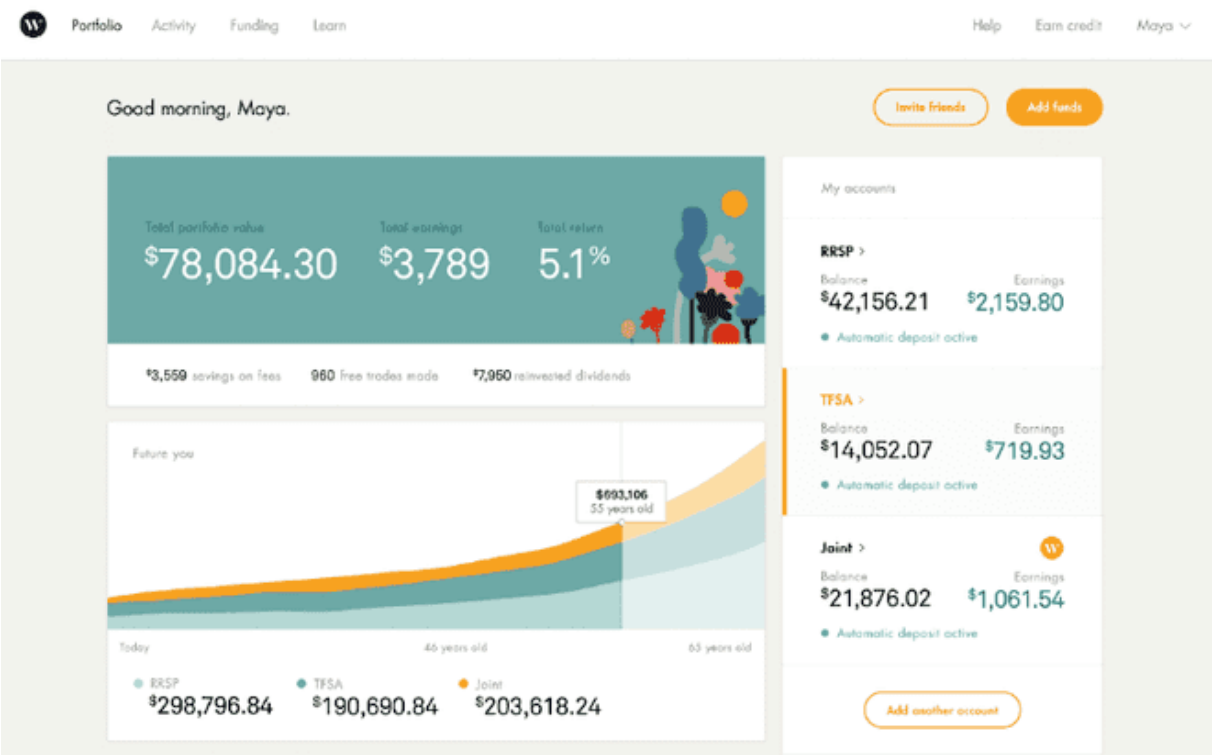

Рисунок 2.3 – Інтерфейс дашборду Wealthsimple

Robo Global застосовує спеціалізований підхід, зосереджуючись на тематичних інвестиціях на основі штучного інтелекту. Їхня система визначає компанії, які можуть отримати вигоду від технологічних зрушень у таких секторах, як робототехніка, автоматизація та штучний інтелект. Платформа використовує алгоритми машинного навчання для відбору тисяч компаній за тематичною експозицією, створюючи концентровані портфоліо навколо конкретних інвестиційних тем. Цей підхід відповідає інтересам інвесторів у цільовій експозиції до трансформаційних тенденцій, зберігаючи при цьому систематичні процеси відбору. Інтерфейс дашборду цієї платформи наведено на рисунку 2.4.

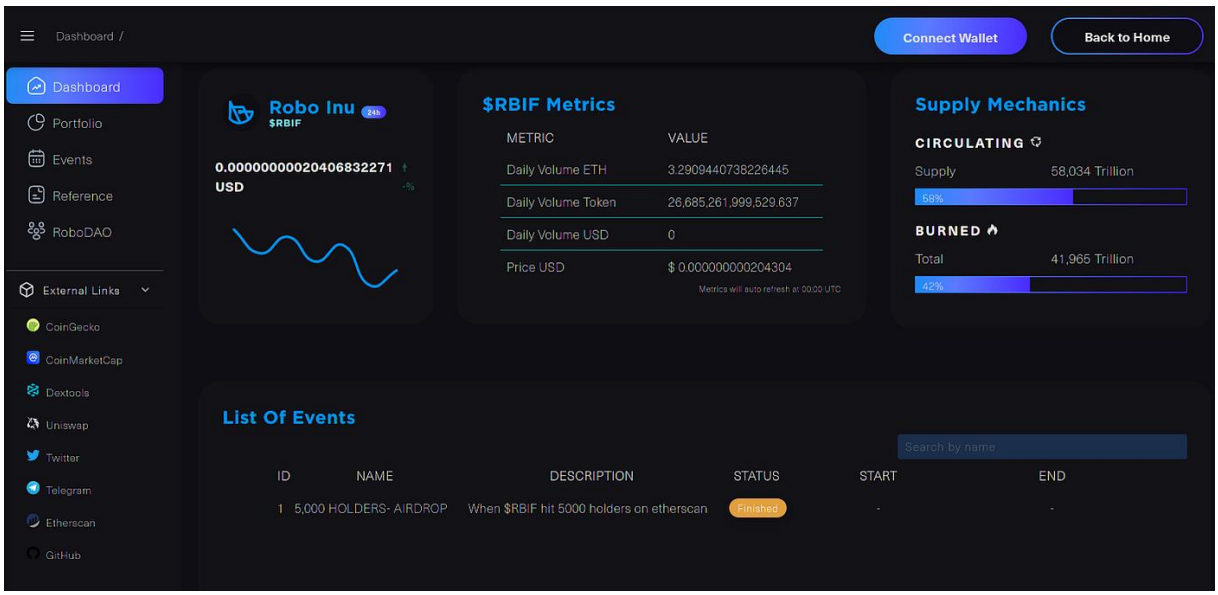

Рисунок 2.4 – Інтерфейс дашборду Robo Global

Aidyia та Quantopian представляли більш експериментальні підходи до алгоритмічного управління інвестиціями. Aidyia використовувала нейронні мережі глибокого навчання для відбору акцій та побудови портфоліо, стверджуючи, що працює без втручання людини в свої інвестиційні рішення. Їхня система обробляла величезні обсяги фінансових даних, новинних настроїв та альтернативних джерел даних для генерації торгових сигналів та розподілу портфоліо. Незважаючи на інноваційність, відсутність прозорості та обмежений досвід роботи платформи підкреслили проблеми у формуванні довіри користувачів до алгоритмічних підходів типу «чорного ящика».

Кілька академічних та науково-дослідних систем досліджували передові застосування машинного навчання для оптимізації портфоліо, надаючи важливі відомості про практичні виклики впровадження складних алгоритмів у реальних інвестиційних контекстах.

Portfolio123 пропонує платформу, яка дозволяє користувачам впроваджувати власні кількісні стратегії, включаючи підходи на основі машинного навчання. Система надає широкі можливості для тестування на історичних даних та доступ до фундаментальних і технічних даних, що

дозволяє дослідникам і практикам розробляти та тестувати складні алгоритми оптимізації портфоліо. Хоча платформа є потужною для досвідчених користувачів, вона вимагає значних технічних знань і не вирішує проблеми доступності, які прагнуть вирішити більш широкі автоматизовані системи портфоліо.

Інтерфейс дашборду платформи Portfolio123 наведено на рисунку 2.5.

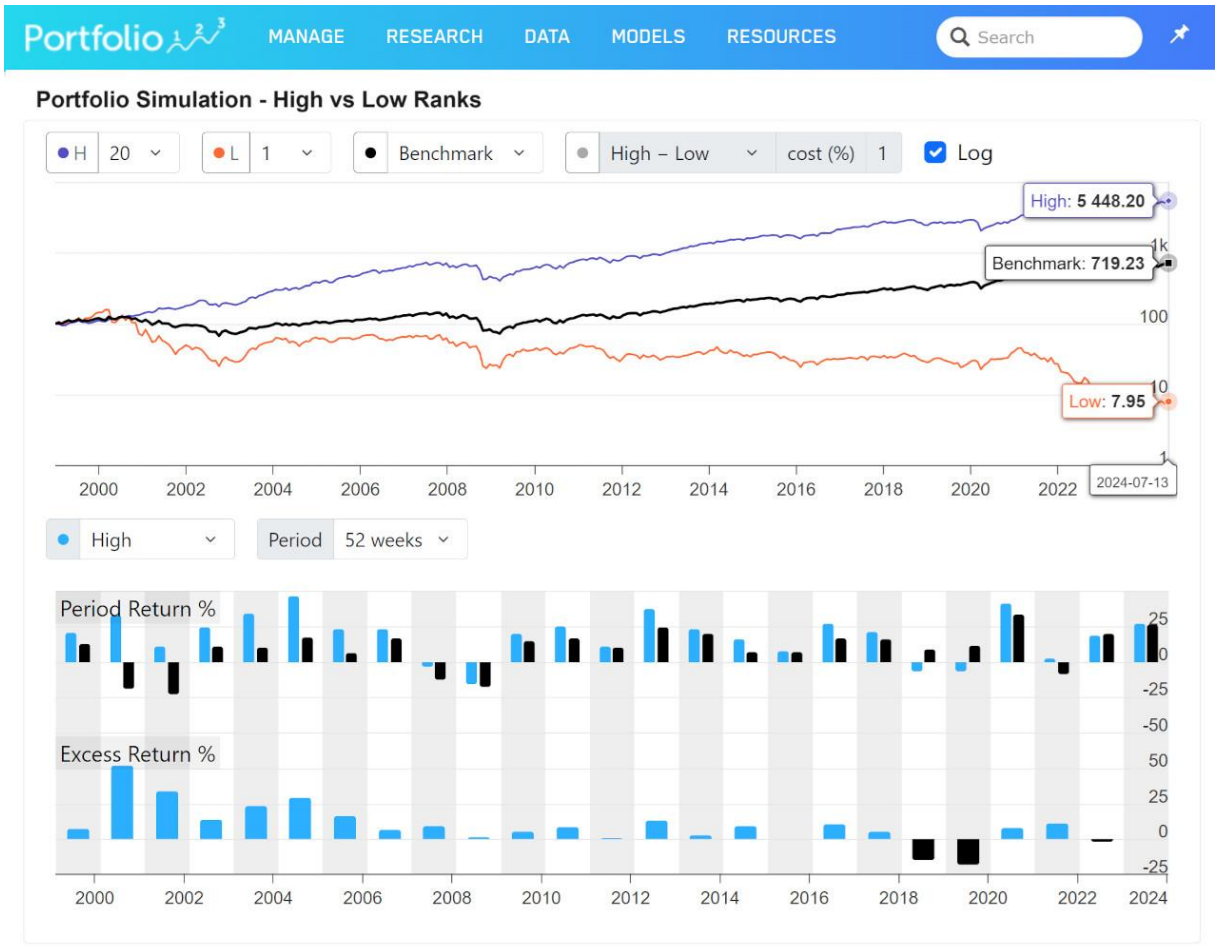

Рисунок 2.5 – Інтерфейс дашборду Portfolio123

QuantConnect і Zipline надають алгоритмічні торгові платформи з відкритим кодом, які підтримують інтеграцію машинного навчання для оптимізації портфоліо. Ці системи вирізняються своєю гнучкістю та прозорістю, дозволяючи дослідникам впроваджувати передові техніки, включаючи нейронні мережі, підкріплювальне навчання та інтеграцію

альтернативних даних. Однак вони залишаються в першу чергу інструментами для кількісних дослідників, а не доступними рішеннями для загальних інвесторів.

Інтерфейс дашборду платформи QuantConnect наведено на рисунку 2.6.

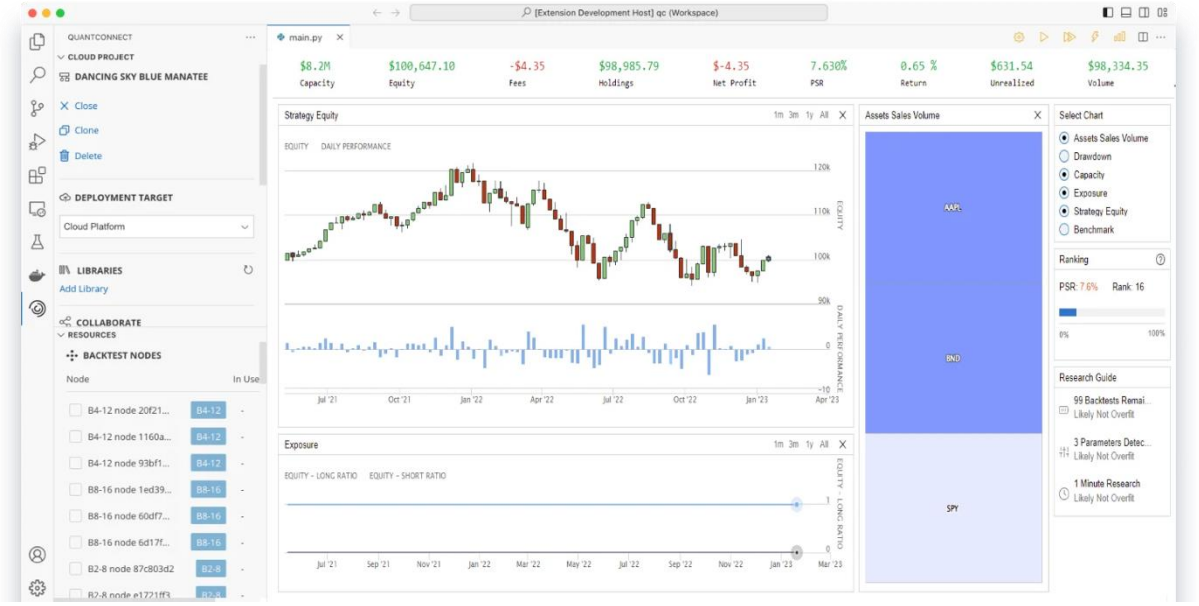

Рисунок 2.6 – Інтерфейс дашборду QuantConnect

Дослідження, проведені Гу, Келлі та Сю у роботі [11] та Чжаном та іншими у роботі [12] продемонстрували потенціал нейронних мереж та підходів глибокого навчання, які перевершують традиційні методи оптимізації портфоліо. Ці академічні дослідження зазвичай зосереджуються на конкретних аспектах процесу побудови портфоліо, таких як прогнозування прибутковості або моделювання ризиків, а не на комплексних системах. Хоча їхні результати є багатообіцяючими, перетворення результатів досліджень на практичні, зручні для користувачів додатки залишається значним викликом.

Незважаючи на значні досягнення в галузі автоматизованого управління портфоліо, існуючі системи мають ряд загальних обмежень, що

створює можливості для вдосконалення підходів. Більшість платформ значною мірою покладаються на традиційні рамки розподілу активів, навіть при використанні компонентів машинного навчання. Це обмежує їх здатність визначати нові підходи до побудови портфоліо або адаптуватися до швидко мінливої динаміки ринку.

Сучасні робо-консультанти зазвичай використовують спрощені профілі користувачів, які можуть недостатньо відображати переваги інвесторів та їхні поведінкові тенденції. Підхід на основі анкет, хоч і є доступним, часто не дозволяє розрізнити нюанси інвестиційних філософій або мінливі ставлення до ризику. Крім того, більшість систем зосереджуються переважно на диверсифікації традиційних класів активів, а не на дослідженні тематичних або факторіальних підходів, які могли б краще відповідати конкретним інтересам інвесторів.

Компроміс між прозорістю та складністю становить постійний виклик для існуючих платформ. Прості, зрозумілі алгоритми можуть не враховувати складності ринку, тоді як складні підходи машинного навчання часто працюють як «чорні скриньки», що підриває довіру користувачів та прийняття регуляторних органів. Лише деякі існуючі системи успішно поєднують складність алгоритмів із розумінням та довірою користувачів.

3 РОЗРОБКА АЛГОРИТМУ СТВОРЕННЯ ІНВЕСТИЦІЙНОГО ПОРТФОЛІО

Система автоматизованого формування портфоліо реалізована у вигляді комплексного фреймворку Python, що складається з шести взаємопов'язаних класів і основного робочого процесу виконання. Ця модульна архітектура дозволяє систематично просуватися від збору необроблених даних через складну оптимізацію портфоліо до комплексної оцінки ефективності. Реалізація використовує перевірені фінансові бібліотеки, одночасно впроваджуючи нові підходи до вибору символів і перекладу уподобань користувачів.

Основою автоматизованої системи є клас BestSymbols, який вирішує важливе завдання перетворення якісних уподобань користувачів у кількісні інвестиційні критерії. Цей компонент значно відрізняється від традиційних підходів на основі анкет, оскільки використовує багатовимірну систему оцінювання, яка аналізує цінні стоки за такими параметрами, як термін, ризик та ефективність.

Клас ініціалізується з ретельно підібраного набору з понад 50 диверсифікованих цінних стоків, що охоплюють основні класи активів та сектори ринку. Частина з них наведена у лістингу 3.1.

Лістинг 3.1 – Програмний код ініціалізації стоків

```
self.symbol_universe = [
    # Large Cap Tech
    'AAPL', 'MSFT', 'GOOGL', 'AMZN', 'META', 'NVDA',
'TSLA',
    # Large Cap Traditional
    'JPM', 'JNJ', 'V', 'PG', 'UNH', 'HD', 'MA', 'DIS',
'BAC',
    # Growth & Innovation
    'NFLX', 'ADBE', 'CRM', 'INTC', 'AMD', 'PYPL', 'SHOP',
    # Defensive & Utilities
```

Продовження лістингу 3.1

```
        'WMT', 'KO', 'PEP', 'MCD', 'VZ', 'T', 'NEE'
        # Additional sectors...
    ]
```

Основна інновація полягає в методі _calculate_symbol_metrics(), який обчислює комплексні фінансові показники для кожного цінного стоку. Цей аналіз виходить за межі традиційних параметрів середнього відхилення і включає індикатори імпульсу в різних часових рамках, показники стабільності та показники поведінкової узгодженості, як наведено у лістингу 3.2.

Лістинг 3.2 – Програмний код визначення метрик стоків

```
    # Momentum metrics (different timeframes)
    momentum_1m = (current_price / price_1m) - 1
    momentum_3m = (current_price / price_3m) - 1
    momentum_6m = (current_price / price_6m) - 1
    momentum_1y = (current_price / price_1y) - 1

    # Consistency metrics
    positive_days_ratio = (symbol_returns > 0).mean()
    rolling_sharpe_std = symbol_returns.rolling(60).apply(
        lambda x: (x.mean() * 252) / (x.std() * np.sqrt(252))
if x.std() > 0 else 0
    ).std()
```

Метод select_symbols() реалізує найскладніший компонент алгоритму: перетворення уподобань користувача в математичні критерії оптимізації. Система будує функції оцінювання за тривалістю, які зважують різні показники ефективності відповідно до термінів інвестування, що наведено у лістингу 3.3.

Лістинг 3.3 – Програмний код визначення показників ефективності до заданих користувачем параметрів інвестування

```
    if duration == 'short':
        # Short-term: Focus on momentum and recent performance
        df['duration_score'] = (
            0.4 * df['momentum_1m'].rank(pct=True) +
            0.3 * df['momentum_3m'].rank(pct=True) +
            0.2 * df['sharpe_ratio'].rank(pct=True) +
            0.1 * df['positive_days_ratio'].rank(pct=True)
        )

    elif duration == 'medium':
        # Medium-term: Balanced approach
        df['duration_score'] = (
            0.3 * df['sharpe_ratio'].rank(pct=True) +
            0.2 * df['annual_return'].rank(pct=True) +
            0.2 * df['momentum_6m'].rank(pct=True) +
            0.15 * df['stability_score'].rank(pct=True) +
            0.15 * (1 -
df['annual_volatility'].rank(pct=True))
        )
```

Цей підхід усуває фундаментальне обмеження існуючих платформ робо-консультантів, дозволяючи здійснювати точне перетворення переваг без необхідності володіння користувачами глибокими фінансовими знаннями. Система оцінки рівня ризику аналогічним чином адаптує ваги, щоб відобразити консервативні, збалансовані або агресивні інвестиційні філософії шляхом систематичного коригування переваг щодо волатильності та очікувань щодо прибутковості.

Клас DataCollector забезпечує надійну основу для збору та попередньої обробки фінансових даних завдяки інтеграції з перевіреними постачальниками даних. При реалізації пріоритетними є надійність та

обробка помилок, при цьому зберігається гнучкість для різних джерел даних. Реалізація логіки завантаження стоку наведена у лістингу 3.4.

Лістинг 3.4 – Програмний код завантаження стоку

```
    def get_stock_data(self, symbols, start_date, end_date):
        """Download stock price data"""
        try:
            # Download data using yfinance
            data = yf.download(symbols, start=start_date,
end=end_date, auto_adjust=False)['Adj Close']

            # Handle single stock case
            if isinstance(data, pd.Series):
                data = data.to_frame(symbols[0])

            # Clean data
            data = data.dropna()

            self.price_data = data
            return data

        except Exception as e:
            print(f"✗ Error downloading data: {e}")
            return None
```

Система включає дані факторної моделі за допомогою методу get_fama_french_factors(), який демонструє практичну адаптивність шляхом реалізації як зовнішнього збору даних, так і генерації синтетичних даних для дослідницьких середовищ, де зовнішній доступ може бути обмеженим. Ця подвійна функціональність забезпечує працездатність алгоритму в різних сценаріях розгортання, зберігаючи при цьому теоретичну строгість.

Клас FamaFrenchModel реалізує комплексну трифакторну модель, яка розширює традиційну оптимізацію портфоліо за допомогою

систематичного розкладання ризику. Цей компонент усуває обмеження оптимізації середнього відхилення, що базується на історичних доходах, шляхом надання прогнозних оцінок очікуваного доходу на основі факторів ризику, що наведено у лістингу 3.5.

Лістинг 3.5 – Програмний код навчання трьохфакторної моделі Фама-Френч

```
    def fit_factor_model(self, symbols=None):
        """Fit Fama-French model for each stock"""
        for symbol in symbols:
            try:
                # Calculate excess returns
                excess_returns = returns_aligned[symbol] -
factors_aligned['RF']

                # Prepare regression data
                X = factors_aligned[['Mkt-RF', 'SMB',
'HML']].values
                y = excess_returns.values

                # Fit regression
                reg = LinearRegression().fit(X_clean, y_clean)

                # Calculate statistics
                self.results[symbol] = {
                    'alpha': reg.intercept_,
                    'beta_market': reg.coef_[0],
                    'beta_smb': reg.coef_[1],
                    'beta_hml': reg.coef_[2],
                    'r_squared': r_squared,
                    'residual_volatility': residual_std
                }
```

Факторна модель має подвійне призначення в рамках більш широкого алгоритму: вона забезпечує покращені оцінки очікуваної дохідності для оптимізації портфоліо та дозволяє проводити систематичний аналіз ризиків шляхом декомпозиції факторної експозиції. Метод get_expected_returns() демонструє, як факторні навантаження перетворюються на прогнозні очікування щодо ефективності, який наведено у лістингу 3.6.

Лістинг 3.6 – Програмний код отримання очікуваного доходу у результаті проведення аналізу моделлю

```
    def get_expected_returns(self, factor_premiums=None):
        """Calculate expected returns using factor loadings"""
        for symbol, loadings in self.results.items():
            expected_return = (
                loadings['alpha'] * 252 +  # Annualize alpha
                loadings['beta_market'] *
factor_premiums['market'] +
                loadings['beta_smb'] * factor_premiums['smb']
+
                loadings['beta_hml'] * factor_premiums['hml']
            )
            expected_returns[symbol] = expected_return
```

Клас PortfolioOptimizer реалізує основний математичний компонент оптимізації, інтегруючи декілька встановлених методологій побудови портфоліо через уніфікований інтерфейс. Цей підхід визнає, що різні ринкові умови та уподобання інвесторів можуть сприяти різним підходам до оптимізації, забезпечуючи алгоритмічну гнучкість при збереженні систематичних процесів прийняття рішень.

Реалізація використовує бібліотеку PyPortfolioOpt для обчислювальної ефективності, розширюючи функціональність за допомогою спеціальних методів, які наведені у лістингу 3.7.

Лістинг 3.7 – Програмний код методів оптимізації портфоліо

```
    def optimize_mean_variance(self, method='max_sharpe'):
        """Mean-variance optimization using PyPortfolioOpt"""
        # Calculate expected returns and covariance matrix
        mu =
expected_returns.mean_historical_return(self.price_data)
        S = risk_models.sample_cov(self.price_data)

        # Optimize portfolio
        ef = EfficientFrontier(mu, S)

        if method == 'max_sharpe':
            weights = ef.max_sharpe(risk_free_rate=0.02)
        elif method == 'min_volatility':
            weights = ef.min_volatility()
        elif method == 'efficient_risk':
            weights =
ef.efficient_risk(target_volatility=0.15)
```

Система реалізує чотири різні підходи до оптимізації: традиційну оптимізацію середнього значення та дисперсії з декількома цільовими функціями, ієрархічну паритетність ризику за допомогою алгоритму HRP та методологію Блека-Літтермана для врахування думок інвесторів. Цей багатометодний підхід дозволяє систематично порівнювати методи оптимізації, забезпечуючи при цьому гнучкість для різних ринкових умов.

Клас RiskAnalyzer вирішує критичні обмеження традиційної оптимізації портфоліо шляхом впровадження комплексної оцінки ризиків, що виходить за межі стандартних показників відхилення. Цей компонент визнає, що ефективне управління портфоліо вимагає розуміння хвостових ризиків, характеристик розподілу та потенційних майбутніх сценаріїв, які історичні показники дисперсії можуть неадекватно відображати.

Впровадження Value-at-Risk демонструє методологічну досконаліть завдяки використанню декількох підходів до розрахунків, що наведені у лістингу 3.8.

Лістинг 3.8 – Програмний код визначення ризиків

```
    def calculate_var_cvar(self, portfolio_weights,
confidence_level=0.05, method='historical'):
        """Calculate Value at Risk and Conditional VaR"""
        if method == 'historical':
            # Historical simulation
            var = np.percentile(portfolio_returns,
confidence_level * 100)
            cvar = portfolio_returns[portfolio_returns <=
var].mean()

        elif method == 'parametric':
            # Parametric approach (assumes normal
distribution)
            mu = portfolio_returns.mean()
            sigma = portfolio_returns.std()
            var = stats.norm.ppf(confidence_level, mu, sigma)

        else:  # monte_carlo
            # Monte Carlo simulation
            simulated_returns =
np.random.multivariate_normal(mu, cov, n_simulations)
            portfolio_sim_returns = np.dot(simulated_returns,
weights_array)
            var = np.percentile(portfolio_sim_returns,
confidence_level * 100)
```

Функція моделювання методом Монте-Карло забезпечує прогнозну оцінку ризиків шляхом створення сценаріїв, усуваючи властиві історичним

методам оцінки ризиків обмеження щодо відображення потенційних майбутніх ринкових умов. Реалізація метода наведена у лістингу 3.9.

Лістинг 3.9 – Програмний код моделювання портфоліо за допомогою метода Монте-Карло

```
    def monte_carlo_simulation(self, portfolio_weights,
days=252, simulations=1000):
        """Monte Carlo simulation for portfolio projections"""
        for i in range(simulations):
            # Generate random walk
            random_shocks = np.random.normal(0, 1, days)
            returns_path = mu * dt + sigma * np.sqrt(dt) *
random_shocks

            # Calculate cumulative value (starting from 100)
            value_path = 100 * np.cumprod(1 + returns_path)
            paths.append(value_path)
            final_values.append(value_path[-1])
```

Клас BacktestEngine реалізує складну оцінку історичної ефективності, яка включає реалістичні торгові обмеження, які часто не враховуються в теоретичних дослідженнях з оптимізації. Цей компонент вирішує проблему розриву між теоретичною ефективністю портфоліо та практичними проблемами реалізації шляхом систематичного включення транзакційних витрат, частоти перебалансування та врахування впливу ринку.

Методологія бектестування реалізує періодичне перебалансування з налаштовуваною частотою та моделюванням транзакційних витрат. Система розраховує комплексні показники ефективності, включаючи прибутковість з урахуванням ризику, аналіз просадки та характеристики розподілу, що забезпечують цілісну оцінку стратегій портфоліо:

Основна функція виконання run_complete_portfolio_optimization() координує весь алгоритмічний процес за допомогою систематичного

робочого процесу, який демонструє практичну інтеграцію всіх компонентів системи. Ця функція реалізує повний конвеєр від обробки вхідних даних користувача до остаточної рекомендації щодо портфоліо та перевірки ефективності.

Робочий процес починається з інтелектуального вибору символів на основі уподобань користувача, продовжується комплексним збором даних і оцінкою факторної моделі, реалізує кілька підходів до оптимізації портфоліо, проводить ретельний аналіз ризиків і завершується перевіркою історичних даних. Цей систематичний підхід гарантує, що кожна рекомендація щодо портфоліо проходить ретельну аналітичну оцінку за кількома параметрами перед тим, як бути представленою користувачам.

Реалізація демонструє кілька ключових інновацій порівняно з існуючими автоматизованими системами портфоліо: перетворення якісних переваг у кількісні критерії оптимізації, систематичне порівняння декількох методологій оптимізації, інтеграція комплексного аналізу ризиків, що виходить за межі традиційних заходів, та включення реалістичних торгових обмежень в оцінку ефективності. Ці компоненти працюють разом, щоб створити надійний, доступний і теоретично обґрунтований підхід до автоматизованого формування портфоліо, який заповнює прогалину між складною фінансовою теорією та практичними потребами інвесторів.

4 ДЕМОНСТРАЦІЯ РОБОТИ АЛГОРИТМУ НА ВЕБ-ПЛАТФОРМІ

Веб-система оптимізації портфоліо пропонує користувачам інтуїтивно зрозумілий, спрощений інтерфейс, який перетворює складний фінансовий аналіз на доступний процес прийняття рішень. Архітектура програми надає пріоритет користувацькому досвіду завдяки ретельно розробленому робочому процесу, який супроводжує інвесторів від початкового визначення переваг до комплексного аналізу портфоліо, не вимагаючи при цьому глибоких фінансових знань.

При вході в систему користувачі бачать розроблену стартову сторінку, яка відразу ж інформує про призначення програми за допомогою чіткої візуальної ієрархії та описових елементів. Інтерфейс використовує сучасний градієнтний фон з напівпрозорими контейнерами вмісту, що створює візуальну глибину, зберігаючи при цьому читабельність на різних пристроях і екранах різних розмірів, та продемонстрований на рисунку 4.1.

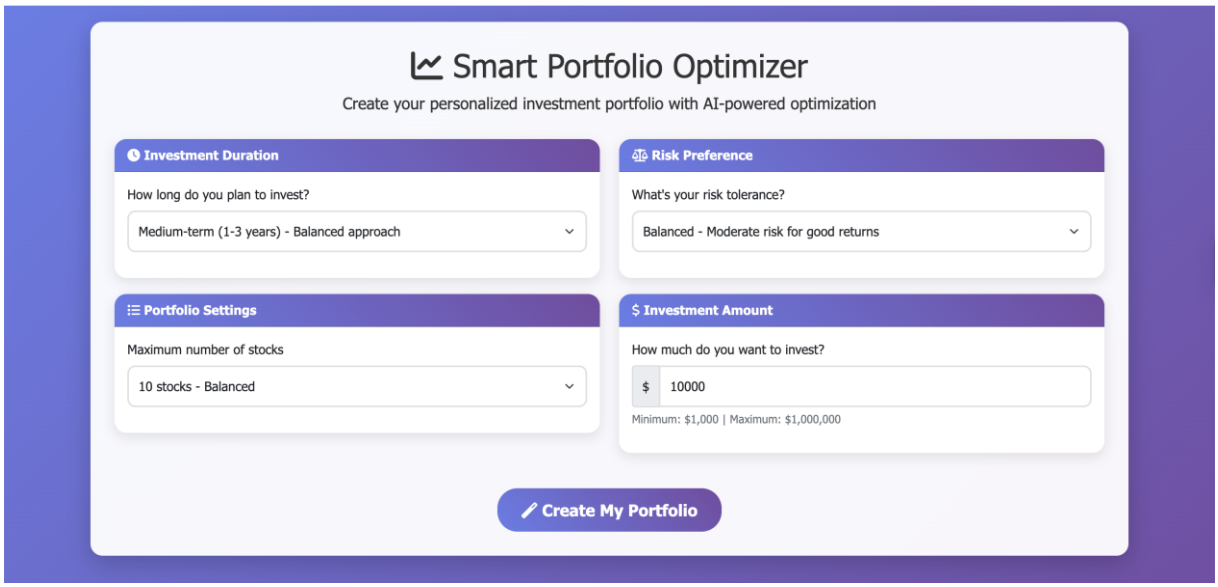

Рисунок 4.1 – Інтерфейс головної сторінки

Основний інтерфейс введення даних організований у чотири окремі розділи, кожен з яких стосується фундаментального аспекту побудови

портфоліо. Цей модульний підхід дозволяє користувачам систематично обробляти інвестиційні рішення, розуміючи, як кожен вибір впливає на їхні остаточні рекомендації щодо портфоліо.

Вибір тривалості інвестиції є першим критичним моментом прийняття рішення, де користувачі визначають терміни своїх інвестицій за допомогою трьох чітко розмежованих опцій:

– короткостроковий (0–1 рік): чітко позначений як орієнтований на стратегії, засновані на імпульсі;

– середньостроковий (1–3 роки): позиціонується як збалансований підхід за замовчуванням;

– довгостроковий (3+ роки): акцент на методологіях, орієнтованих на стабільність.

Ця часова категоризація має подвійну мету: вона спрощує складне визначення переваг для користувачів, одночасно дозволяючи базовому алгоритму коригувати параметри оптимізації відповідно до встановлених принципів інвестиційної теорії.

Конфігурація ризикових переваг перетворює традиційні анкети щодо толерантності до ризику на три інтуїтивні категорії, які уникають фінансового жаргону, зберігаючи при цьому аналітичну точність:

– консервативна: «Нижчий ризик, стабільні доходи» – орієнтована на інвесторів, які не схильні до ризику;

– збалансована: «Помірний ризик для хороших доходів» – служить системним стандартом;

– фгресивна: «Вищий ризик для потенційно високих прибутків» – для стратегій, орієнтованих на зростання.

Налаштування диверсифікації портфоліо дозволяють користувачам вказати бажану кількість активів за допомогою п'яти попередньо визначених опцій, від концентрованих (5 акцій) до високодиверсифікованих (20 акцій) портфоліо. Кожна опція містить описові позначення, які допомагають користувачам зрозуміти наслідки їхнього

вибору концентрації без необхідності детального знання теорії диверсифікації.

Вказання суми інвестицій приймає значення в доларах, з вбудованою перевіркою та чітким повідомленням про межі. Цей діапазон підходить як для індивідуальних роздрібних інвесторів, так і для тих, хто має значний інвестиційний капітал, при цьому зберігаючи практичні обмеження системи.

Після подання своїх уподобань користувачі бачать інтерфейс завантаження, який замінює форму введення даних і забезпечує чітку комунікацію про процес аналізу, що відбувається. Інтерфейс цієї сторінки наведено на рисунку 4.2.

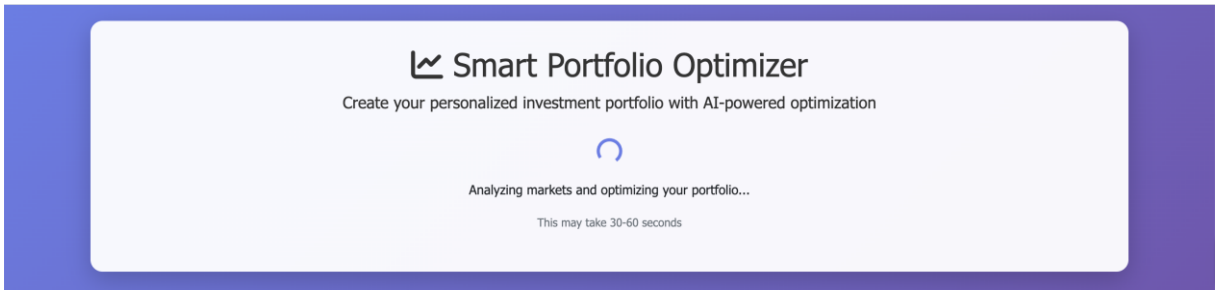

Рисунок 4.2 – Інтерфейс сторінки формування портфоліо

Екран завантаження містить три важливі елементи: візуальний індикатор, що показує активну обробку, пояснювальний текст, що описує поточні аналітичні дії («Аналіз ринків та оптимізація вашого портфеля...»), та реалістичні очікування щодо часу («Це може зайняти 30–60 секунд»). Такий підхід запобігає плутанині користувачів під час обчислювально-інтенсивних процесів оптимізації, одночасно формуючи довіру до ретельності системи.

Інтерфейс результатів є основною частиною веб-порталу, представляючи комплексний фінансовий аналіз за допомогою декількох взаємодоповнюючих підходів до візуалізації та узагальнення. Архітектура

презентації забезпечує баланс між вичерпністю інформації та когнітивною доступністю, гарантуючи, що користувачі можуть зрозуміти рекомендації щодо свого портфеля, не відчуваючи перевантаження.

Основна інформація про результати формування портфоліо наведена на рисунку 4.3.

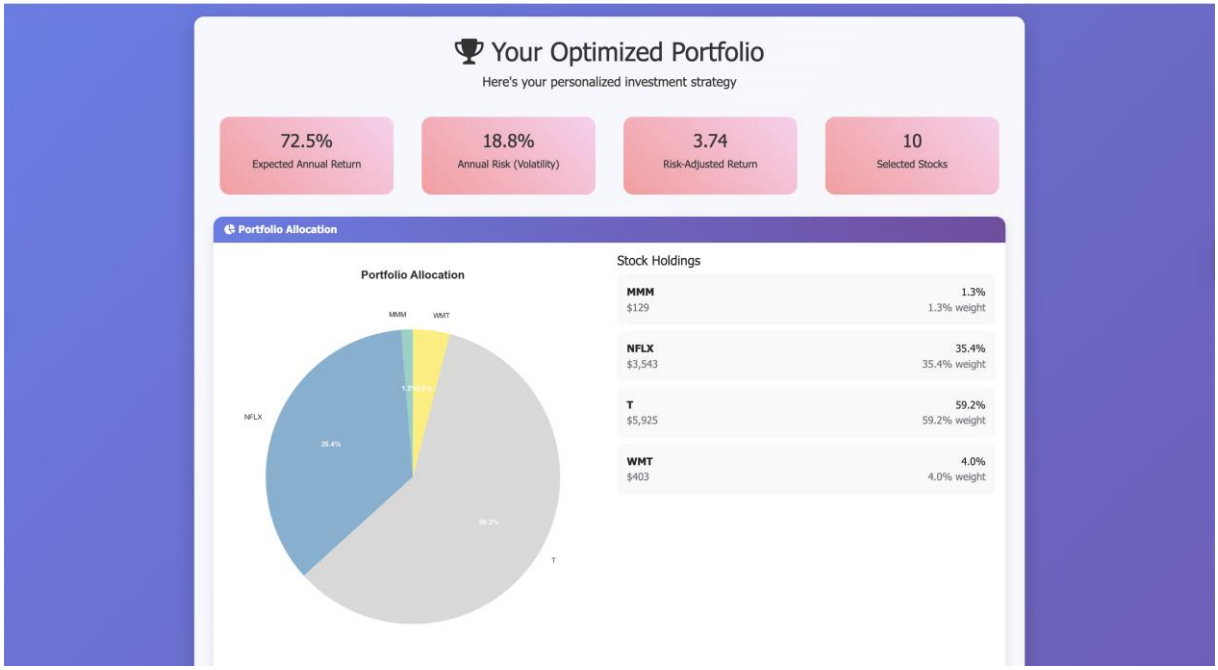

Рисунок 4.3 – Інтерфейс результатів сформованого портфоліо

Узагальнення результатів портфоліо відразу ж представляє чотири ключові показники у вигляді візуально помітних карток:

– очікувана річна дохідність: відображається у вигляді відсотка з чітким позначенням;

– річний ризик (волатильність): представлений разом з очікуваною дохідністю для контексту;

– прибутковість з урахуванням ризику: коефіцієнт Шарпа, представлений у доступній термінології;

– вибрані акції: простий підрахунок компонентів портфеля.

Такий підхід до узагальнення дозволяє користувачам швидко оцінити основні характеристики свого портфоліо, перш ніж заглиблюватися в детальний аналіз.

Візуалізація розподілу портфоліо поєднує візуальне та текстове представлення інформації за допомогою подвійних панелей. Ліва панель містить кругову діаграму, що показує пропорційний розподіл, а права панель надає детальну інформацію про активи, включаючи:

– індивідуальні символи акцій із відсотковим розподілом;

– суми в доларах для кожної позиції на основі зазначеної суми інвестицій;

– вага кожного цінного стоку в портфоліо.

Розділ «Аналіз ризиків» перекладає складні показники ризику на зрозумілу мову за допомогою ретельного маркування та контекстних пояснень та представлений на рисунку 4.4.

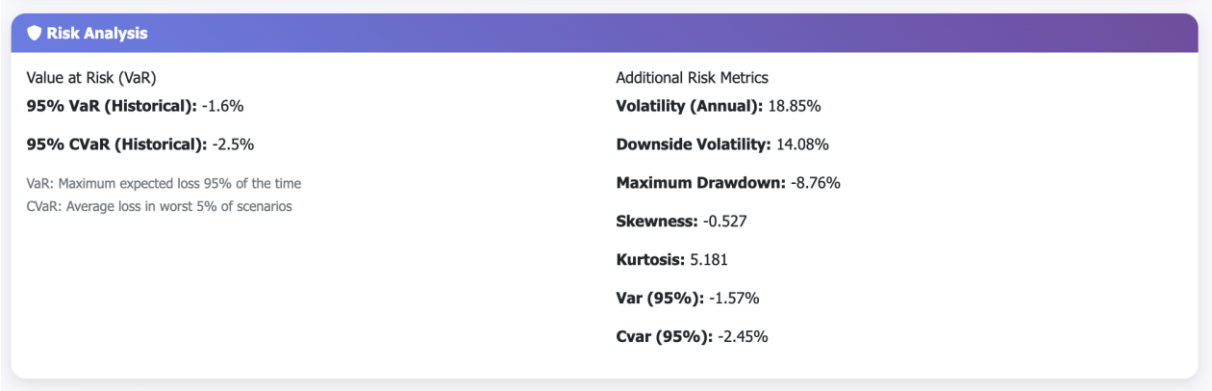

Рисунок 4.4 – Інтерфейс результатів аналізу ризиків

Розрахунки вартості під ризиком (VaR) та умовної вартості під ризиком (CVaR) представлені з чіткими визначеннями: «VaR: максимальний очікуваний збиток у 95% випадків» та «CVaR: середній збиток у найгірших 5% сценаріїв». Додаткові показники ризику, включаючи показники волатильності, аналіз просадки та характеристики розподілу,

забезпечують комплексну оцінку ризику, зберігаючи доступність завдяки послідовному форматуванню та пояснювальному контексту.

Система включає в себе декілька складних аналітичних діаграм, які забезпечують більш глибоке розуміння структури портфоліо та очікуваної дохідності. Ці візуалізації демонструють аналітичну глибину програми, залишаючись при цьому зрозумілими для користувачів з різним фінансовим досвідом.

Аналіз розсіювання ризику та дохідності позиціонує окремі цінні стоки в рамках комплексної системи ризику та дохідності, виділяючи вибрані компоненти портфоліо на тлі більш широкого спектру доступних інвестицій, що наведено на рисунку 4.5.

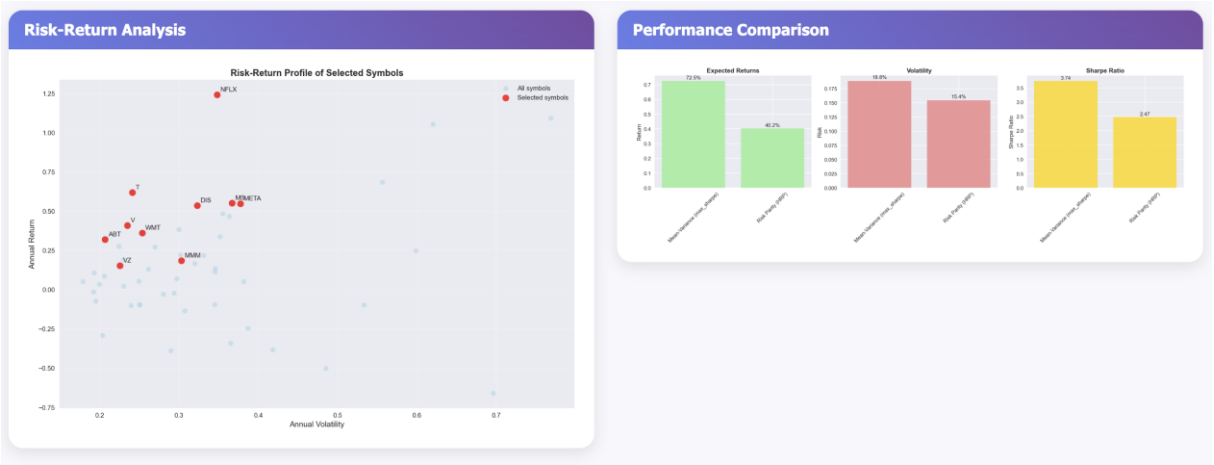

Рисунок 4.5 – Інтерфейс аналізу розсіювання ризику

Ця візуалізація дозволяє користувачам зрозуміти, чому були обрані конкретні стоки та як вони сприяють досягненню загальних цілей портфоліо.

Діаграми порівняння ефективності відображають порівняння методологій оптимізації за допомогою паралельних гістограм, що показують очікувані доходи, показники волатильності та показники ефективності з урахуванням ризику. Така презентація дозволяє

користувачам зрозуміти відносні переваги різних підходів до формування портфоліо, одночасно зміцнюючи довіру до обраної методології.

Візуалізація прогнозів за методом Монте-Карло є, мабуть, найскладнішим аналітичним компонентом, що представляє ймовірні результати портфеля за допомогою подвійних панелей, які наведені на рисунку 4.6.

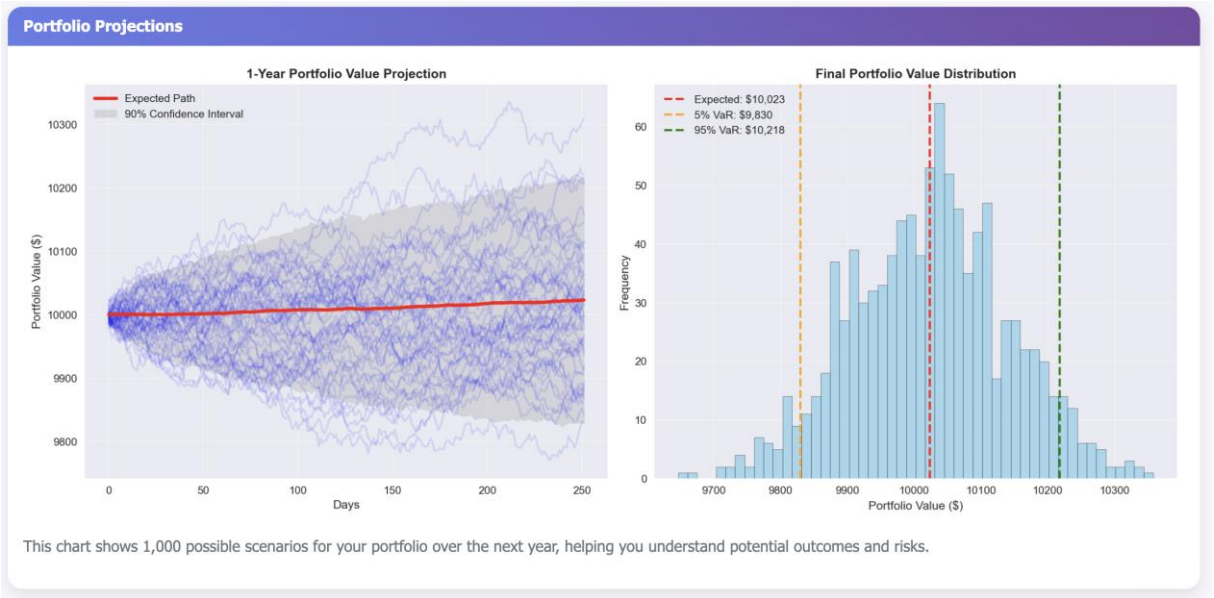

Рисунок 4.6 – Інтерфейс візуалізації прогнозів метолом Монте-Карло

Ліва панель показує потенційні траєкторії вартості портфеля протягом одного року, включаючи середні траєкторії та довірчі інтервали, а права панель представляє розподіл результатів з чітко позначеними процентилями та очікуваними значеннями. Супровідний пояснювальний текст гарантує, що користувачі розуміють ці прогнози як аналіз сценаріїв, а не як гарантовані передбачення.

Інтерфейс доповнюється практичними елементами підтримки прийняття рішень, які враховують як поточні, так і довгострокові потреби користувачів. У підсумку інвестиційного профілю повторно відображаються введені користувачем дані, які наведені на рисунку 4.7,

разом із вибором методології оптимізації, що забезпечує прозорість перетворення переваг у аналітичні підходи.

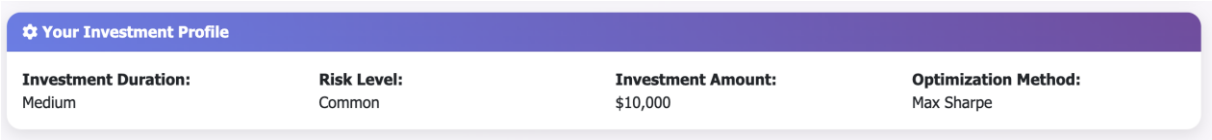

Рисунок 4.7 – Інтерфейс вхідних даних користувача

Кнопки дій забезпечують ефективну навігацію по системі за допомогою двох основних шляхів: створення нових портфоліо з різними параметрами та друк результатів для офлайн-довідки, що наведені на рисунку 4.8.

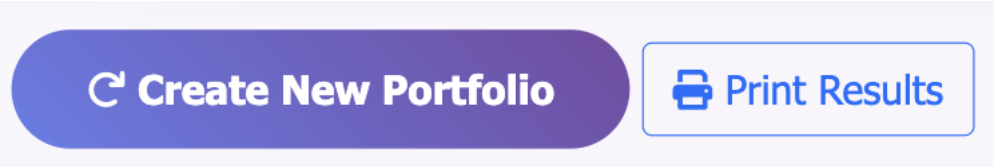

Рисунок 4.8 – Інтерфейс навігації після генерації портфоліо

Ця функціональність враховує, що оптимізація портфоліо часто передбачає ітеративне експериментування з різними специфікаціями переваг.

Обробка помилок та надійність системи демонструють професійний дизайн додатка завдяки зручному для користувача відображенню помилок, яке уникає технічного жаргону та надає чіткі шляхи відновлення. Екрани помилок зберігають візуальну узгодженість із загальним інтерфейсом, одночасно пропонуючи негайну навігацію назад до інтерфейсу введення даних.

ВИСНОВКИ

Кваліфікаційна робота успішно демонструє доцільність і практичну цінність інтеграції передових алгоритмів оптимізації портфоліо з інтуїтивно зрозумілими веб-інтерфейсами, створюючи комплексну систему підтримки інвестиційних рішень, яка заповнює прогалину між складною фінансовою теорією та практичною доступністю для інвесторів. Розроблена програма є значним внеском у поширення кількісного управління портфоліо, перетворюючи складні математичні процеси оптимізації на зручні для користувача інструменти, які зберігають аналітичну строгість і водночас підвищують ефективність прийняття рішень.

Дослідження завершилося кількома суттєвими технічними досягненнями, які сприяють як теоретичному розумінню, так і практичному впровадженню систем оптимізації портфоліо. Інтелектуальний алгоритм вибору символів представляє новий підхід до попередньої оптимізації, що поєднує кілька аналітичних вимірів, включаючи аналіз імпульсу, показники ефективності з урахуванням ризику та обмеження диверсифікації секторів. Ця багатокритеріальна методологія відбору успішно зменшує обчислювальну складність оптимізації портфоліо, одночасно покращуючи якість вхідних стоків за допомогою систематичної оцінки понад 60 окремих акцій у різних секторах ринку.

Інтеграція декількох методологій оптимізації в єдину структуру демонструє значну технічну досконаліть. Система успішно реалізує оптимізацію середнього відхилення для портфоліо з максимальним коефіцієнтом Шарпа, ієрархічні підходи до паритету ризиків для збалансованого розподілу ризиків та методологію Блека-Літтермана для врахування думок інвесторів. Кожна техніка оптимізації зберігає математичну точність, забезпечуючи порівнянні показники ефективності, що дозволяє користувачам зрозуміти компроміси між різними філософіями побудови портфоліо.

Можливості аналізу ризиків є ще одним важливим технічним досягненням, що включає розрахунки ризику вартості та умовної вартості за допомогою історичного моделювання та параметричних підходів. Архітектура моделювання Монте-Карло забезпечує ймовірнісні прогнози портфеля на різні часові горизонти, генеруючи тисячі потенційних сценаріїв для ілюстрації діапазону можливих результатів. Ці складні інструменти оцінки ризиків безперебійно працюють в архітектурі веб-додатку, забезпечуючи аналіз інституційної якості через доступні для споживачів інтерфейси.

Ця кваліфікаційна робота успішно демонструє доцільність і практичну цінність інтеграції передових алгоритмів оптимізації портфоліо з інтуїтивно зрозумілими веб-інтерфейсами, створюючи комплексну систему підтримки інвестиційних рішень, яка заповнює прогалину між складною фінансовою теорією та практичною доступністю для інвесторів. Розроблена програма є значним внеском у поширення кількісного управління портфоліо, перетворюючи складні математичні процеси оптимізації на зручні для користувача інструменти, які зберігають аналітичну строгість і водночас підвищують ефективність прийняття рішень.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Markowitz H. Portfolio Selection. *The Journal of Finance*. 1952. Т. 7, № 1. С. 77. URL: https://doi.org/10.2307/2975974 (дата звернення: 14.06.2025).

2. Reinforcement-Learning Based Portfolio Management with Augmented Asset Movement Prediction States / Y. Ye та ін. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020. Т. 34, № 01. С. 1112–1119. URL: https://doi.org/10.1609/aaai.v34i01.5462 (дата звернення: 15.05.2025).

3. Samsudin N. Portfolio Optimization using Reinforcement Learning. *Medium*. URL: https://medium.com/analytics-vidhya/portfolio-optimization-using-reinforcement-learning-1b5eba5db072 (дата звернення: 15.05.2025).

4. Wu J., Li H. Deep Ensemble Reinforcement Learning with Multiple Deep Deterministic Policy Gradient Algorithm. *Mathematical Problems in Engineering*. 2020. Т. 2020. С. 1–12. URL: https://doi.org/10.1155/2020/4275623 (дата звернення: 15.05.2025).

5. Sharpe Ratio: How to Identify Winning Investments. *Hivelr*. URL: https://www.hivelr.com/2023/05/sharpe-ratio-how-to-identify-winning-investments/ (дата звернення: 15.05.2025).

6. Gu S., Kelly B., Xiu D. Empirical Asset Pricing via Machine Learning. Cambridge, MA : National Bureau of Economic Research, 2018. URL: https://doi.org/10.3386/w25398 (дата звернення: 15.05.2025).

7. Prado M. L. d. Advances in Financial Machine Learning. Gildan Media, 2018.

8. Fischer T., Krauss C. Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*. 2018. Т. 270, № 2. С. 654–669. URL: https://doi.org/10.1016/j.ejor.2017.11.054 (дата звернення: 15.05.2025).

9. Heaton J. B., Polson N. Deep Learning for Finance: Deep Portfolios. *SSRN Electronic Journal*. 2016. URL: https://doi.org/10.2139/ssrn.2838013 (дата звернення: 15.05.2025).

10. Brinson G. P., Hood L. R., Beebower G. L. Determinants of Portfolio Performance. *Financial Analysts Journal*. 1986. Т. 42, № 4. С. 39–44. URL: https://doi.org/10.2469/faj.v42.n4.39 (дата звернення: 15.05.2025).

11. Gu S., Kelly B., Xiu D. Empirical Asset Pricing via Machine Learning. Cambridge, MA : National Bureau of Economic Research, 2018. URL: https://doi.org/10.3386/w25398 (дата звернення: 14.06.2025).

12. Zhang Z., Zohren S., Roberts S. Deep Learning for Portfolio Optimization. *The Journal of Financial Data Science*. 2020. Т. 2, № 4. С. 8–20. URL: https://doi.org/10.3905/jfds.2020.1.042 (дата звернення: 14.06.2025).

13. 40 Days With Jesus: Services And Video Clips (Igniting Worship). Abingdon Press, 2006. 112 с.

14. Deep learning-based time series forecasting / X. Song та ін. *Artificial Intelligence Review*. 2024. Т. 58, № 1. URL: https://doi.org/10.1007/s10462-024-10989-8 (дата звернення: 15.05.2025).

15. Portfolio Optimization with Constraints. *Portfolio Optimization*. 2010. С. 153–178. URL: https://doi.org/10.1201/b17178-12 (дата звернення: 14.06.2025).

16. Portfolio Optimization with Constraints. *Portfolio Optimization*. 2010. С. 153–178. URL: https://doi.org/10.1201/b17178-12 (дата звернення: 14.06.2025).

17. Sharpe Ratios under Constraints, and Kinks. *Portfolio Optimization*. 2010. С. 205–228. URL: https://doi.org/10.1201/b17178-14 (дата звернення: 14.06.2025).

18. Gridin I. Deep Learning for Portfolio Optimization: Introduction. *Medium*. URL: https://medium.com/@survexman/deep-learning-for-portfolio-optimization-introduction-f098f4b83ed3 (date of access: 14.06.2025).

19. 胥 智. Portfolio Management Problem Based on Deep Reinforcement Learning. *Operations Research and Fuzziology*. 2023. Т. 13, № 03. С. 1427–1441. URL: https://doi.org/10.12677/orf.2023.133144 (дата звернення: 14.06.2025).

20. 梅 星. Stock Price Prediction Based on ARIMA-LSTM Combination Model. *E-Commerce Letters*. 2024. Т. 13, № 04. С. 5833–5846. URL: https://doi.org/10.12677/ecl.2024.1341822 (дата звернення: 14.06.2025).