

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ХЕРСОНСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ
Факультет комп'ютерних наук, фізики та математики
Кафедра комп'ютерних наук та програмної інженерії

**Прогнозування динаміки цін криптовалют з використанням
техніки машинного навчання**

Кваліфікаційна робота (проект)
на здобуття ступеня вищої освіти “магістр”

Виконав: здобувач 2 курсу 261Мз групи
Спеціальність: 126 Інформаційні системи та
технології»
Освітньо-професійна програма:
Інформаційні системи та технології
Молікевич Роман Сергійович
Керівник: проф., д-р. ф.-м. н. Львов М.С.
Рецензент: доц., к.т.н., в.о. завідувача
кафедри програмних засобів і технологій,
Херсонський національно-технічний
університет
Огнева О. Є.

Івано-Франківськ – 2024

ЗМІСТ

ВСТУП.....	3
РОЗДІЛ 1. ТЕОРЕТИЧНІ ЗАСАДИ ПРОГНОЗУВАННЯ ЦІН КРИПТОВАЛЮТ.....	6
1.1. Особливості ринку криптовалют.....	6
1.2. Методи прогнозування часових рядів для фінансових інструментів.....	9
1.3. Методи машинного навчання для прогнозування цін фінансових інструментів.....	12
РОЗДІЛ 2. ФОРМУВАННЯ ПОЧАТКОВОГО ІНВЕСТИЦІЙНОГО ПОРТФЕЛЮ ЗА МОДЕЛЛЮ МАРКОВІЦА.....	14
2.1. Формування переліку криптовалют для інвестиційного портфелю.....	14
2.2 Розробка початкового інвестиційного портфелю за моделлю Марковіца.....	17
РОЗДІЛ 3. РОЗРОБКА МОДЕЛЕЙ ПРОГНОЗУВАННЯ ЦІН КРИПТОВАЛЮТ НА ОСНОВІ ТЕХНІКИ МАШИННОГО НАВЧАННЯ ДЛЯ РЕБАЛАНСУВАННЯ ІНВЕСТИЦІЙНОГО ПОРТФЕЛЮ.....	30
3.1 Підготовка даних для прогнозування курсу криптовалют.....	30
3.2 Навчання та тестування моделей машинного навчання для прогнозування та класифікації.....	32
3.3 Оцінка інвестиційного портфелю щодо прогнозних цін та його оптимізація.....	36
ВИСНОВКИ.....	40
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	45

ВСТУП

Актуальність теми. Сучасний фінансовий світ характеризується високою динамічністю та інноваційністю. Одним із найяскравіших проявів цих тенденцій є бурхливий розвиток ринку криптовалют. Їхня волатильність, децентралізованість та технологічна основа створюють унікальні можливості для інвестування, але водночас і значні ризики. Прогнозування майбутніх цін на криптовалюти є складним, але надзвичайно важливим завданням для інвесторів, трейдерів та аналітиків. Точні прогнози можуть допомогти уникнути збитків, оптимізувати інвестиційні портфелі та розробити ефективні торгові стратегії.

Цінові ряди криптовалют часто демонструють складні нелінійні патерни, які важко виявити за допомогою традиційних статистичних методів. Також, сучасні фінансові платформи генерують величезні обсяги даних про ціни, обсяги торгів, соціальні настрої тощо. Машинне навчання дозволяє ефективно обробляти та аналізувати такі дані. Сучасні комп'ютери та програмне забезпечення забезпечують високу швидкість обчислень, що необхідна для навчання складних моделей машинного навчання.

Метою дослідження є формування інвестиційного портфелю з наступною розробкою та оцінкою моделей машинного навчання для прогнозування динаміки цін криптовалют.

Завдання дослідження полягають в наступному:

- 1) аналіз особливостей ринку криптовалют та їх впливу на ефективність прогнозування;
- 2) формування початкового інвестиційного портфелю за моделлю Марковіца;

3) розробка моделей прогнозування цін криптовалют на основі техніки машинного навчання для ребалансування інвестиційного портфелю.

Об'єкт дослідження : історичні дані про ціни криптовалют та різноманітні алгоритми машинного навчання, які застосовуються для прогнозування та створення інвестиційних портфелів.

Предмет дослідження: процес прогнозування динаміки цін криптовалют за допомогою методів машинного навчання та оцінка ефективності різних моделей для розробки оптимальної інвестиційної стратегії.

Методи дослідження. Використано систематичний огляд літератури для ідентифікації ефективних алгоритмів машинного навчання для довгострокового прогнозування цін криптовалют та розробки оптимальної моделі машинного навчання. Вибрані алгоритми навчаються та тестуються за допомогою технічних індикаторів RSI, EMA, SMA, розрахованих на історичних даних про ціни за період з червня 2017 року по червень 2024 року, отриманих з API CoinGecko. Підбір інвестиційного портфелю за моделлю Морковніца. Оцінка точності моделей за допомогою матриці похибок. Ребалансування інвестиційного портфелю на основі прогнозних показників. Порівняння інвестиційних портфелів для різних інвестиційних стратегій.

Наукова новизна. Дослідження спрямоване на розширення знань про застосування методів машинного навчання у сфері фінансового прогнозування, зокрема, для криптовалютного ринку. Очікується, що результати дослідження внесуть свій вклад у розвиток теоретичних основ та практичних інструментів для аналізу та прогнозування фінансових ринків.

Практичне значення одержаних результатів. Результати дослідження можуть бути використані для розробки інвестиційних стратегій (створення алгоритмічних торгових систем, які базуються на

прогнозах моделей машинного навчання), управління ризиками (оцінки потенційних ризиків інвестування в криптовалюти та розробки стратегій хеджування), аналізу ринку (виявлення закономірностей та трендів на ринку криптовалют). Таким чином, дане дослідження є актуальним та перспективним, оскільки воно спрямоване на вирішення важливої практичної проблеми та має потенціал для внесення значного внеску в розвиток фінансової інженерії.

Апробація результатів роботи та публікації. Для апробації результатів досліджень було прийнято участь у міжнародній науковій конференції "Штучний інтелект у науці та освіті (AISE 2024)" (Київ, 1-2 березня 2024 р.), яка була організована ДНУ «Український інститут науково-технічної експертизи та інформації» та Інститутом цифровізації освіти НАПН України. За результатами участі отримано сертифікат учасника та опубліковано тези на тему: " Використання машинного навчання для прогнозування цін криптовалют".

Робота складається з вступу, 3-х розділів, висновків, списку використаних джерел (загальним обсягом 41 джерело). Загальний обсяг роботи 42 сторінки друкованого тексту.

РОЗДІЛ 1

ТЕОРЕТИЧНІ ЗАСАДИ ПРОГНОЗУВАННЯ ЦІН КРИПТОВАЛЮТ

1.1. Особливості ринку криптовалют

В останні роки криптовалюти змінили уявлення людей про фінансові транзакції та переформатували традиційну фінансову індустрію. Поява криптовалют відкрила перед інвесторами нові можливості для успішних інвестицій. Криптовалюти є віртуальними валютами, які базуються на технології блокчейн, децентралізованій системі обліку, що дозволяє безпечний та відкритий обмін без необхідності центрального органу управління [1]. Децентралізований характер криптовалют робить їх менш уразливими для маніпуляцій з боку фінансових установ, ніж традиційні валюти. Інвестори, які намагаються точно прогнозувати коливання цін та здійснювати прибуткові інвестиції, стикаються з проблемами через надзвичайно високу волатильність та непередбачуваність ринку криптовалют. Щоб подолати це, інвестори використовують різні техніки, такі як аналіз часового ряду, фундаментального та технічного аналізу за допомогою алгоритмів машинного навчання [2].

Криптовалюта - це зашифрована цифрова валюта, яка запобігає підробці та подвійному витрачання. Вона не створюється централізованим органом влади чи банківською системою і є розподіленою віртуальною валютою, якою можна торгувати за допомогою зашифрованих засобів. Видобуті віртуальні валюти можна придбати на криптобіржі. Крім того, не всі сайти електронної комерції приймають оплату криптовалютами. Навіть такі відомі криптовалюти, як Bitcoin, рідко використовуються для роздрібних транзакцій. Натомість криптовалюти набули популярності як торгові інструменти

завдяки зростанню їхньої вартості. Їх також обмежено використовують для міжнародних переказів [3].

Блокчейн - це технологія, яка підтримує Bitcoin і переважну більшість інших криптовалют. Вона підтримує незмінний реєстр подій і веде облік того, хто чим володіє. Усі транзакції peer-to-peer записуються в блокчейн, який є децентралізованим реєстром. Учасники можуть перевіряти транзакції навіть без необхідності централізованого органу управління, використовуючи цю технологію. На фундаментальному рівні блокчейн є публічно перевірюваним каталогом транзакцій з можливістю публічної перевірки. Залежно від того, як вони використовуються, складові одиниці цифрових валют відомі як монети або токени. Деякі призначені для використання як засоби обміну товарів або послуг, деякі - як сховища вартості, а інші - для участі в певних програмних додатках, таких як ігри та інвестиційні деривативи [4].

Однією з найпопулярніших і глобально визнаних криптовалют є Bitcoin. Bitcoin був першою створеною криптовалютою і був запущений групою програмістів під псевдонімом Сатоші Накамото у січні 2009 року [5]. Вартість 1 Bitcoin зросла з \$357,24 у листопаді 2015 року до \$19 891,99 у грудні 2017 року, але знову впала до мінімуму \$11 509,31 у жовтні 2020 року, а потім знову зросла до максимуму \$ 73 737,94 \$ у березні 2024 року і послідує падіння ціни знову [6]. Це показує, що інвестування в криптовалюту має потенціал для отримання значних прибутків, але також несе ризик значних втрат через свою волатильність.

Незважаючи на всі наведені факти, Bitcoin є високо ризикованою інвестицією. Криптовалюта не відповідає економічним якостям валюти, виходячи з погляду та характеристики традиційних грошей. Крипторинок є одним із найпривабливіших місць для фінансових спекулянтів, що свідчить про зростання шахрайської діяльності в соціальних мережах. Деякі інвестори, особливо ті, хто має високий

апетит до ризику, зацікавлені в інвестиціях у Bitcoin [7]. Багато людей отримали значні прибутки від спекуляцій на цифровому ринку. Зрозуміло що, аналітики ринку та спекулянти використовують прогнози. Через різницю в прогнозній надійності кожної окремої монети алгоритми машинного навчання та штучного інтелекту є досить цікавими сьогодні [8,9].

Іншою основною валютою є Ефіріум (ETH) - це криптовалюта, випущена у 2015 році на основі технології Ефіріум, яка є провідною у світі програмованою блокчейн-платформою. На відміну від інших блокчейн-систем, Ефіріум є програмованим, що означає, що розробники можуть використовувати його для створення нових типів додатків, які можуть контролювати цифрові активи для створення нових типів фінансових додатків [10]. Ethereum - це децентралізована блокчейн-мережа, яка захопила світ штурмом, здійнявши хвилю як у фінансовій, так і в технологічній галузях. Вона вдихнула нове життя в інтернет, відкривши нову еру Web 3.0, визначену децентралізованими додатками (DApps), смарт-контрактами та цифровими активами, які працюють на основі протоколу Ethereum [11,12]. Всупереч думці, що всі криптовалюти ідентичні, Ethereum вирізняється як дійсно унікальна та універсальна платформа. На відміну від біткоіну, який є в першу чергу цифровою валютою і засобом збереження вартості, Ethereum - це програмований блокчейн, який дозволяє створювати і виконувати смарт-контракти і децентралізовані додатки (DApps). Ця програмованість відкриває світ можливостей для розробників, дозволяючи їм створювати інноваційні додатки, які використовують потужність технології блокчейн. Ефіріум, як і будь-яка інша криптовалюта, демонструє значну волатильність цін. Ці коливання обумовлені різноманітними факторами, включаючи загальні настрої на ринку, новини про розробку платформи, регуляторні зміни та інші події. Історичний максимум ETH у розмірі \$4,878.26 був зафіксований 10 лист 2021 р. [13].

Біткоїн та Ефіріум залишаються основними криптовалютами, які є визначальними у коливанні курсу інших криптовалют [14].

1.2 Методи прогнозування часових рядів для фінансових інструментів

Фінансовий ринок визначається як ринок, на якому відбувається торгівля фінансовими інструментами [15]. Інші дослідники визначають фінансові ринки як місця, де різні типи фінансових інструментів можуть бути продані та/або обміняні різними суб'єктами на основі їхньої ціни, яка впливається попитом і пропозицією на ринку [16].

Фінансові ринки використовують різні типи фінансових інструментів. Усі фінансові інструменти належать до певного типу фінансового ринку [17]. Також можна знайти різні класифікації фінансових ринків: наприклад, D. Kidwell диференціює фінансові ринки на первинні та вторинні, організовані та неорганізовані, інституційні та внутрішні ринки [18]. На вторинному фінансовому ринку торгуються такі фінансові інструменти, як акції, облігації, ф'ючерси та форварди, опціони, валюти, цінні папери позик та інші, нещодавно отримані інструменти.

Вчені виділяють три основні стратегії торгівлі фінансовими інструментами – фундаментальний, технічний та кількісний методи аналізу [19]. Також, варто наголосити, що фундаментальний аналіз ґрунтується на різних економічних факторах для визначення реальної вартості цінних паперів, тоді як технічний аналіз базується на історичній вартості активу та даних про обсяги торгів [20].

Фундаментальний аналіз оцінює фінансовий стан бізнесу – грошові потоки, доходи, результати діяльності, кредитні ризики та інші фактори, що дозволяють зробити висновки про вартість компанії. На відміну від фундаментального аналізу, технічний аналіз зосереджується

на змінах ціни фінансового інструменту. Цей метод використовує широкий спектр візуалізаційних технік (тренди, лінії опору та підтримки тощо) для визначення моменту купівлі або продажу фінансового інструменту.

Найновішою галуззю є кількісний аналіз, який зосереджений на вивченні та розробці складних математичних моделей і використанні статистичних методів аналізу[21].

Як технічний, так і кількісний аналіз фінансових інструментів застосовують математичні та статистичні методи для допомоги інвесторам у визначенні найоптимальнішого моменту для відкриття або закриття позиції. Останнім часом методи штучного інтелекту, такі як машинне навчання, глибинне навчання та нейронні мережі, дедалі частіше використовуються в кількісному аналізі [22].

Кількісна торгівля – це будь-яка форма торгівлі, що використовує складні алгоритми (програмовані системи) для автоматизації всіх або кількох торгових циклів. Вона також включає кодування правил, які має виконувати комп'ютер, а також проведення тестування на історичних даних (backward testing) або перспективного тестування (forward testing) [23].

Кількісну торгівлю можна розділити на дві частини: створення математичних моделей для аналізу та прогнозування і розробку автоматизованої торгової системи шляхом програмування. Кількісний аналіз значною мірою спирається на статистику та застосування математичних методів.

Оскільки фінансові дані є даними часових рядів, кількісний аналіз також можна назвати аналізом часових рядів. Аналіз часових рядів базується на аналізі даних для знаходження оптимальної моделі, яка найкращим чином відповідає наданим даним. Основною метою цього аналізу є створення моделі, яку можна успішно екстраполювати на

майбутні дані. Аналіз часових рядів широко використовується для нестабільних даних, саме такі дані генеруються на фінансових ринках.

Методи прогнозування часових рядів поділяються на дві групи: засновані на статистичних концепціях і засновані на методах комп'ютерного інтелекту, таких як машинне навчання, нейронні мережі або генетичні алгоритми. Найпопулярніші статистичні методи прогнозування часових рядів включають методи експоненціального згладжування, регресійні методи, методи інтегрованих авторегресивних середніх ковзних (ARIMA), порогові методи, а також методи узагальненої авторегресивної умовної гетероскедастичності або авторегресивної умовної гетероскедастичності (GARCH/ARCH).

З огляду на проведені дослідження та на основі оглядів, знайдених у наукових джерелах, можна зробити висновок, що в більшості випадків дослідницькі роботи або аналіз даних фінансових інструментів розглядаються в контексті алгоритмів машинного навчання, таких як: логістична регресія; випадкові ліси (RF); машини опорних векторів (SVM); метод найближчих сусідів (kNN) [24].

Традиційний статистичний метод ARIMA генерує відповідні прогнозовані значення ціни для фінансового інструменту. З цієї причини для перевірки ефективності двох методів прогнозування підходять лише регресійні методи контрольованого навчання, оскільки класифікаційні методи розподіляють прогнозовані дані за категоріями. Це означає, що такі методи більше підходять для виявлення тенденцій – чи зростає, чи падає ціна фінансового інструменту.

Огляд літератури свідчить про те, що для прогнозування цін акцій часто використовуються методи машинного навчання, зокрема нейронні мережі та машини опорних векторів (SVM). Як нейронні мережі, так і SVM є стандартними методами машинного навчання, які можуть бути використані для прогнозування даних часових рядів завдяки своїм особливостям [25]. Машини опорних векторів (SVM) належать до

алгоритмів машинного навчання з контрольованим навчанням. Цей алгоритм можна застосовувати для прогнозування цін фінансових інструментів.

На основі досліджень, знайдених у наукових базах даних, можна стверджувати, що алгоритм SVM використовується в більшості випадків або комбінується з іншими алгоритмами. Також алгоритм SVM застосовується не лише на фінансових ринках, а й в інших галузях завдяки своїй універсальності. Популярність і застосовність цього методу можна пояснити високою сукупною продуктивністю та добре розробленим математичним підходом до навчання алгоритму.

1.3. Методи машинного навчання для прогнозування цін фінансових інструментів

Для реалізації дослідницьких завдань, ми розглянули два сімейства моделей машинного навчання: градієнтні бустингові машини (GBM) та рекурентні нейронні мережі (RNN), які обидві адаптовані до прогнозування серій цін криптовалют. У попередніх дослідженнях було продемонстровано, що як GBM, так і RNN досягають надійних оцінок серій цін криптовалют [26]. Більш конкретно, градієнтні бустингові машини змогли з високою точністю передбачити як стабільні тенденції, без слідів короткострокових піків/падінь, так і нестабільні. З іншого боку, рекурентні нейронні мережі були менш точними в моделюванні стабільних тенденцій цін.

GBM є поєднанням дерев класифікації та регресії [27]. Основна ідея полягає в тому, щоб покращити одну слабку модель, поєднавши її з іншими слабкими моделями для створення колективної сильної моделі. У GBM ітеративне генерування слабких моделей визначається мінімізацією градієнта над вибраною функцією втрат. XGBoost, LightGBM і CatBoost є трьома основними сучасними GBM.

XGBoost є відкритим, масштабованим і розподіленим GBM, який будує дерева паралельно, а не послідовно. З іншого боку, Microsoft LightGBM характеризується вищою швидкістю навчання та ефективністю, досить низьким використанням пам'яті та масштабованістю. CatBoost вводить впорядкований бустинг, щоб уникнути зміщення прогнозу навченої моделі, що є поширеною проблемою для традиційних тренувань GBM.

Рекурентні нейронні мережі (RNN) – це тип нейронних мереж, де поведінка внутрішніх нейронів залежить не лише від стану інших внутрішніх нейронів на попередньому кроці обчислень, але й від більш ранніх етапів обробки інформації. Процес навчання RNN часто є складним через проблему нестабільності градієнта. Це означає, що під час навчання мережі, градієнти (тобто, сигнали, які інформують мережу, як змінити свої параметри) можуть ставати дуже великими або дуже маленькими. Як наслідок, прості RNN мають труднощі з запам'ятовуванням інформації протягом тривалих періодів часу. Це обмежує їх здатність робити точні прогнози на основі даних, зібраних протягом тривалого часу [28].

RNN є потужним інструментом для роботи з послідовними даними. Хоча вони мають свої обмеження, такі як проблема зникаючих градієнтів, вони продовжують активно розвиватися і застосовуватися в різних областях.

РОЗДІЛ 2

ФОРМУВАННЯ ПОЧАТКОВОГО ІНВЕСТИЦІЙНОГО ПОРТФЕЛЮ ЗА МОДЕЛЛЮ МАРКОВІЦА

2.1. Формування переліку криптовалют для інвестиційного портфелю

Як відповідь на постійні зміни в оточенні, інвестори коригують структуру своїх портфелів, щоб максимізувати цільовий коефіцієнт прибутковості та ризику. У періоди стійко низьких процентних ставок, як це було продемонстровано протягом останнього десятиліття у світі, традиційні інвестиції стають менш цікавими, і інвестори шукають альтернативні форми інвестування у пошуках вищої прибутковості та, можливо, нижчого ризику, отриманого шляхом диверсифікації портфеля. У цьому контексті криптовалюти як альтернативна форма інвестування привернули все більшу увагу багатьох інвесторів і цього дослідження. Основною вимогою, яку повинна задовольняти кожна нова альтернативна форма інвестування, є внесок з точки зору диверсифікації Марковіца, тобто внесок у більш сприятливе співвідношення між прибутковістю та ризиком портфеля, що саме й намагається дослідити це дослідження для портфеля криптовалют.

Останні роки стали свідками активного вивчення ролі криптовалют в інвестиційних портфелях. Науковці досліджували як вплив окремих цифрових валют, зокрема біткойна [29], на портфелі, що включають традиційні активи, так і ефективність цілих портфелів криптовалют, представлених індексами на кшталт CRIX [30]. Більшість досліджень підтверджують позитивний вплив криптовалют на співвідношення ризику та прибутковості інвестицій [31].

Розуміючи характеристики криптовалют як класу активів, дослідники оцінювали портфелі криптовалют, використовуючи різні

підходи до формування портфеля та порівнюючи їхню ефективність. Найпоширенішими стратегіями формування портфеля є: правило рівного зважування $1/N$, так звана наївна диверсифікація, стратегія оптимізації середньоквадратичного відхилення Марковіца, принцип паритету ризику, максимальне співвідношення Шарпа або просто використання портфеля CRIX [32]. Існують різні виграшні стратегії залежно від спостережуваного періоду та вибірки.

Виникає актуальне питання: які критерії мають відповідати криптовалюти, аби бути включеними до інвестиційного портфеля? Очевидно, що не всі цифрові активи однаково придатні для інвестування, оскільки мають різні характеристики. Більшість попередніх досліджень фокусувалися на криптовалютах з найбільшою ринковою капіталізацією. Іноді вибір обмежувався індексами, такими як CRIX, або популярністю монет. Лише деякі дослідження враховували важливий фактор ліквідності при відборі криптовалют [33].

У дослідженні Сімона Трімборна було відібрано криптовалюти до портфелів у поєднанні зі акціями. Враховуючи високу волатильність і відносно низьку ліквідність, замість стандартної моделі середньоквадратичного відхилення вони пропонують метод LIBRO (оптимізація ризик-прибутковість з обмеженням ліквідності) [34]. На додаток до прибутковості та ризику, ліквідність також розглядається як міра ефективності портфеля.

Варіації волатильності та прибутковості, а також інших специфічних для активу показників, таких як ліквідність і привабливість, слід включати відповідним і всебічним чином у моделі оптимізації портфеля, що включають криптовалюти [35]. Саме тому в цьому дослідженні розглядається набір різних і специфічних для криптовалют критеріїв. Це досить новий підхід у відборі портфеля криптовалют, оскільки деякі дослідження використовували ліквідність лише як передумову для відбору активів у портфель, тоді як

привабливість була доведена лише в часовому аналізі для впливу на ціни та прибутковість криптовалют.

Для того, щоб дослідити загальну тенденцію зміни цін на криптовалюти, ми обрали період з 13 червня 2021 року по 14 червня 2024 року. Аналіз базується на даних про щоденну прибутковість, отриманих з фінансового веб-сайту <https://www.coingecko.com/>. Для аналізу були обрано 15 криптовалют з високими показниками капіталізації: Bitcoin (BTC), Ethereum (ETH), BNB, Solana (SOL), Dogecoin (DOGE), Toncoin (TON), Cardano (ADA), Avalanche (AVAX), NEAR protocol (NEAR), PEPE, Optimism (OP), Arbitrum (ARB), Cosmos (ATOM), Poligon (MATIC), Aptos (APT).

Нижче наведемо графік динаміки ціни BTC за обраний період (рис 2.1.). Ціна біткойна стартувала з \$35666.15 13 червня 2021 року, що є найвищою початковою ціною порівняно з рештою криптовалют у цій роботі. І досягла піку в \$ 73 737,94 у березні 2024 року, що становить \$38071.79 різниці між найвищою та найнижчою ціною за обраний період часу.




Рис. 2.1. Приклад графіка динаміки ціни BTC за обраний період.

Висока волатильність ціни доводить, що криптовалюта має широкий діапазон коливань історичних цін, з високим ризиком, але водночас вона також матиме високу прибутковість. Наприклад, біткойн має приблизно \$64 000 від початку до найвищої точки, що доводить, що біткойн має високу волатильність і високий ризик, але він також може значно зрости. Інші цифрові валюти мали високі ціни протягом 2021 року, що свідчить про те, що ринок вважав ці цифрові валюти такими, що мають високу цінність або потенціал для зростання. Після 2021 року всі обрані монети має тенденцію до зниження цін, що свідчить про зниження загального ринку. Наступний ріст почався наприкінці 2023 та початку 2024 року. На кінець досліджуваного періоду ціни почали стабілізуватись і навіть зменшуватись. За прогнозами наступний ріст почнеться традиційно наприкінці осені/початку зими. Однак висновок отримано лише з історичних даних. Більш конкретний прогноз необхідно зробити шляхом аналізу фундаментальних показників компанії, перспектив галузі та ринкового середовища.

2.2. Розробка початкового інвестиційного портфелю за моделлю Марковіца

В нашому дослідженні використано теорію та модель Марковіца як основну модель, використовуючи середовище R для обчислювальних завдань, таких як аналіз даних і розв'язання моделей. Модель Марковіца відома як модель середнього значення-дисперсії, яка була запропонована американським економістом Гаррі Марковіцем у 1952 році [36]. Методологія цієї моделі спрямована на побудову ефективних інвестиційних портфелів шляхом врахування коваріації та кореляції між активами для максимізації очікуваної прибутковості при мінімізації ризику. Основна ідея моделі Марковіца полягає у зменшенні загального ризику портфелю шляхом диверсифікації інвестицій між активами, що

дозволяє інвесторам вибирати оптимальні портфелі на різних рівнях ризику. Модель вводить поняття ефективного кордону, за допомогою математичних методів оптимізації інвестори можуть знайти портфелі, які пропонують максимальну прибутковість при заданому рівні ризику та мінімальний ризик при заданому рівні прибутковості. [37].

Для вивчення портфелів криптовалют ми поєднуємо модель Марковіца з техніками аналізу даних, щоб сформувавши наш дослідницький метод. Метод включає збір даних, розрахунок добової прибутковості, розрахунок річної прибутковості та коваріаційної матриці, випадкове розподілення ваг, розрахунок коефіцієнта Шарпа та визначення оптимального портфеля за ефективною межею. Модель описує портфель, який максимізує очікувану прибутковість при мінімізації ризику. Ефективна межа представляє мінімальний рівень ризику для заданого рівня очікуваної прибутковості. Ці результати дозволяють інвесторам кількісно оцінювати та порівнювати потенційні ризики та прибутковість різних інвестиційних стратегій, надаючи потужний інструмент для прийняття раціональних інвестиційних рішень [38].

Ми застосували модель Марковіца як основний інструмент для визначення найкращого портфеля в роботі. Ця модель забезпечує потужну основу для вибору портфеля.

Модель Марковіца є оптимізаційною моделлю. Цільова функція включає:

$$\min \sum_{i=1}^n \sum_{j=1}^n w_i w_j \text{cov}(i, j),$$

$$\max \sum_{i=1}^n ER_i w_i. \quad (2.1)$$

Обмеження включають:

$$\sum_{i=1}^n w_i = 1,$$

$w_i \geq 0, i=1,2,\dots,n, j=1,2,\dots,n,$

w_i представляє вагу i -го активу;

w_j представляє вагу j -го активу;

$\text{cov}(i,j)$ представляє коваріацію між прибутками i -го та j -го активу;

ER_i представляє очікувану прибутковість i -го активу.

Обмеження означають, що сума ваг портфеля повинна дорівнювати 1, а ваги для кожного активу не повинні бути від'ємними.

У центрі теорії моделі Марковіца лежить зменшення загального ризику портфеля шляхом специфічної стратегічної диверсифікації різних активів. Ця стратегічна диверсифікація дозволяє інвесторам знайти найкращий портфель для різних ризикових активів. Ця модель вводить поняття ефективного кордону. Використовуючи складні математичні методи оптимізації, інвестори можуть систематично визначати портфелі, які забезпечують максимальну прибутковість при заданому рівні ризику або мінімальний ризик при заданому рівні прибутковості. Метою цього модуля є максимізація його прибутковості та мінімізація ризику.

Також, використовувався коефіцієнт Шерпа. Коефіцієнт Шарпа, розроблений Вільямом Ф. Шарпом у 1966 році, широко використовується як фінансовий показник, що відображає співвідношення між очікуваною прибутковістю та очікуваним ризиком. Він слугує важливим інструментом для інвесторів, допомагаючи їм оцінити, чи очікувана прибутковість достатньо покриє пов'язаний з нею ризик. Вищий коефіцієнт Шарпа означає кращу скориговану на ризик ефективність, що вказує на те, що портфель генерує вищу прибутковість

на одиницю ризику. І навпаки, нижчий коефіцієнт Шарпа означає протилежне явище.

$$\text{Sharpe ratio} = (E(R_p) - R_f) / \sigma_p, (2.2)$$

де

$E(R_p)$ - очікувана прибутковість портфеля;

R_f - безризикова ставка портфеля;

σ_p - стандартне відхилення прибутковості портфеля, що також відноситься до ризику портфеля.

У роботі ми припускаємо, що безризикова ставка буде 0, тому формулу можна перетворити в просту форму:

$$\text{Sharpe ratio} = E(R_p) / \sigma_p (2.3)$$

Для проведення відповідного аналізу було обрано 15 криптовалют (рис. 2.2).

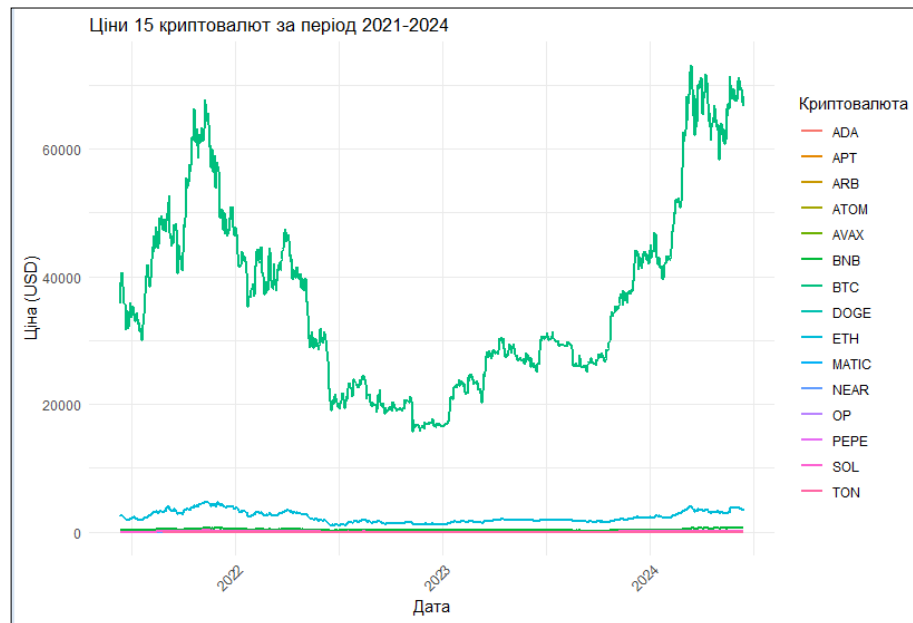


Рис. 2.2. Графік динаміки цін обраних криптовалют за період

Також, додатково було побудовано box plot -графік (рис. 2.3), за яким можна зробити більш послідовні висновки відносно зміни цін криптовалют за обраний період:




Рис. 2.3. Тенденції обраних криптовалют

1) BTC (Bitcoin) - має дуже широкий діапазон значень на графіку, що відображає істотні коливання ціни. Це відповідає поведінці Bitcoin, який відомий своєю волатильністю. Високий розмах (різниця між мінімумом і максимумом) вказує на значні зміни у вартості за період 2021-2024.

2) ETH (Ethereum) теж має високу ціну та широкий діапазон, хоча його розмах трохи менший порівняно з Bitcoin. Це може свідчити про дещо меншу волатильність, хоча Ethereum також зазнавав великих коливань.

3) SOL (Solana) та BNB (Binance Coin) - обидві криптовалюти також демонструють значний розмах, хоча їхня вартість набагато менша за Bitcoin та Ethereum. Solana виглядає дещо стабільнішою, оскільки має менший розмах.

4) ADA (Cardano), APT (Aptos), AVAX (Avalanche) - ці криптовалюти розташовані в середньому ціновому діапазоні. Вони мають досить широкий діапазон значень, але не такі екстремальні, як у Bitcoin або Ethereum.

5) DOGE (Dogecoin) має широкий діапазон, але знаходиться ближче до нижньої частини графіка. Це свідчить про те, що він має нижчу середню ціну, хоча зазнавав великих коливань під час "мем" буму.

6) OP і PEPE - ці криптовалюти мають найбільш низьку вартість серед усіх, причому PEPE розташований в області дуже низьких цін. Це відповідно мем-токен та менш популярний проєкти з дуже низькою ринковою капіталізацією.

На основі побудованого графіка (рис. 2.4), гістограми показують розподіл щоденної прибутковості для наших криптовалют. Кожен графік демонструє, як часто спостерігаються різні значення прибутковості за вказаний період. За графіками також можна зробити узагальнені висновки:

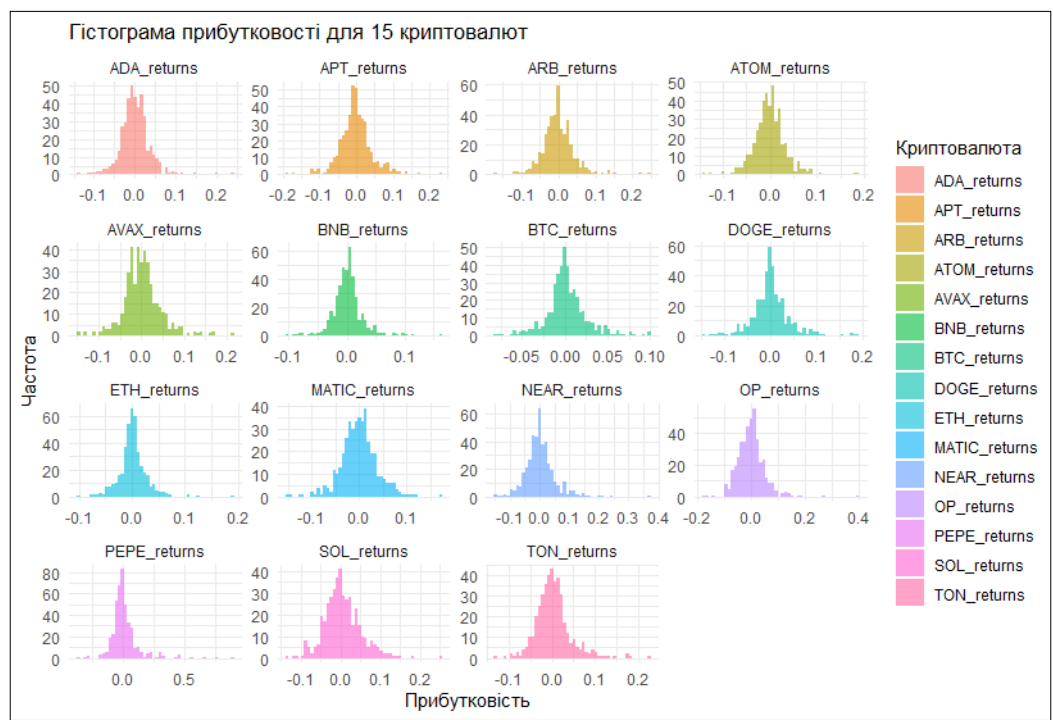


Рис. 2.4. Графік прибутковості обраних криптовалют

1) Більшість криптовалют мають симетричний розподіл, близький до нормального, що є типовим для фінансових інструментів. Наприклад, для Bitcoin (BTC) і Ethereum (ETH) графіки прибутковості мають

нормальний розподіл, який концентрується навколо нуля, що означає, що більшість днів були нейтральними (не суттєве зростання чи падіння).

2) Оптимізм (OP), Aptos (APT) і Pepe (PEPE) показують широкий діапазон прибутковості, що вказує на високу волатильність. Наприклад, для OP прибутковість може досягати 0.4, а для PEPE – навіть більше. У той час як такі криптовалюти як BTC та ETH мають значно вужчий діапазон, що вказує на меншу волатильність порівняно з менш відомими або новими криптовалютами.

3) Dogecoin (DOGE), Solana (SOL), BNB, MATIC мають більшу частоту зміни ціни близько нуля, що може свідчити про більш стабільну поведінку. Проте криптовалюти з більш широким розподілом, такі як Pepe та Optimism, можуть бути більш ризикованими для інвесторів через непередбачувані зміни ціни.

4) Деякі криптовалюти показують ознаки асиметрії, тобто одна сторона гістограми є більш «довгою». Це може свідчити про випадки великих прибутків або втрат. Наприклад, графіки для ARB та AVAX виглядають більш асиметричними, що свідчить про наявність більш рідкісних, але значних змін ціни.

5) Pepe та Optimism виділяються як найволатильніші криптовалюти серед представлених. Bitcoin і Ethereum, як найбільші за капіталізацією криптовалюти, демонструють найстабільніші розподіли, що є очікуваним.

Також, нами було виконано коваріаційну матрицю для криптовалют (рис. 2.5). Коваріація є статистичною мірою, яка використовується для оцінки зв'язку між двома випадковими змінними. Зокрема, вона показує, як дві змінні змінюються з часом і чи змінюються вони в одному напрямку (позитивна коваріація) чи в протилежному напрямку (негативна коваріація). Позитивна коваріація означає, що коли одна змінна зростає, інша змінна також має тенденцію до зростання, і навпаки, що вказує на позитивну кореляцію. Навпаки, негативна

коваріація вказує на те, що коли одна змінна зростає, інша змінна має тенденцію до зменшення, і навпаки, що вказує на негативну кореляцію.




Рис. 2.5. Теплокарта кореляційної матриці криптовалют

За результатами даного аналізу було зроблено наступні висновки:

1) Значення кореляції для пар, таких як BTC та ETH (0.977), BTC та SOL (0.980), а також ETH та SOL (0.949), свідчать про сильний позитивний зв'язок. Це означає, що ціни на ці активи, як правило, змінюються в одному напрямку. BNB також має сильну кореляцію з основними криптовалютами, такими як BTC (0.915) та DOGE (0.931), що вказує на їх узгоджені цінові коливання.

2) DOGE і PEPE демонструють високий рівень кореляції (0.863). Це може свідчити про схожу ринкову динаміку або вплив загальних новин чи подій, які одночасно впливають на їх ціни. DOGE також має сильну кореляцію з TON (0.866) і BNB (0.931), що вказує на значний вплив спекулятивних настроїв на ці криптовалюти.

3) ATOM і TON мають дуже слабкий зв'язок (0.028), що може вказувати на різну природу цінових коливань цих активів. ARB також демонструє слабкий зв'язок із деякими активами, наприклад, з TON (-0.005). Це свідчить про те, що ці криптовалюти можуть мати унікальні

фактори впливу або інші моделі ринкової поведінки, незалежні від загального криптовалютного ринку.

4) APT (Aptos) та NEAR демонструють високий рівень кореляції з основними криптовалютами, такими як ETH і SOL (наприклад, APT-ETH = 0.735, APT-SOL = 0.722). Це може вказувати на те, що нові проекти частково наслідують цінові коливання більших платформ. ARB і OP показують помірний рівень кореляції з BTC та ETH (наприклад, ARB-BTC = 0.418), що може свідчити про поступове залучення цих активів до основного криптовалютного ринку.

5) Такі криптовалюти, як ADA та AVAX, демонструють високі кореляції між собою (0.944). Це може бути пов'язано з тим, що вони обидві виступають альтернативами для створення блокчейн-платформ та мають схожі економічні фактори.

6) MATIC та PEPE мають низький рівень кореляції (0.138). Це може свідчити про те, що мем-криптовалюти (як PEPE) мають унікальну ринкову динаміку порівняно з платформними активами, такими як MATIC. TON має доволі низькі кореляції з деякими активами, такими як ARB (-0.005), що може вказувати на незалежний характер цього активу або вплив інших факторів (наприклад, телекомунікаційних чи регуляторних).

У нашому аналізі ми використовуємо випадкові числа в \mathbb{R} для моделювання випадкового розподілу ваги між криптовалютами. Зокрема, ми моделюємо 50 000 портфелів, кожен з яких складається з набору випадково згенерованих ваг. Щоб продемонструвати можливість методу оптимізації портфеля, ми вибрали велику кількість портфелів. Ми використовуємо модель середньо-квадратичного відхилення Марковіца як метод оптимізації портфеля. У кожному конкретному випадку (наприклад, для заданого рівня ризику або очікуваної норми прибутковості) ми будемо ефективною межу, обчислюючи коваріаційну матрицю між активами та очікувану норму прибутковості. Потім ми

вибираємо оптимальний портфель таким чином, щоб максимізувати коефіцієнт Шарпа або мінімізувати дисперсію. Наприклад, для заданого рівня ризику ми можемо показати, яким є оптимальне алокування в певній точці на ефективній межі для максимізації очікуваної прибутковості або мінімізації ризику. Такий аналіз допомагає продемонструвати ефективність нашого підходу та зменшити ризик, пов'язаний з вибором одного портфеля.

Використовуючи згадані раніше формули, ми отримуємо 50 000 різних інвестиційних портфелів, кожен з яких характеризується унікальними значеннями прибутковості та волатильності. Прибутковість і волатильність цих портфелів потім візуалізуються за допомогою діаграми розсіювання, де кожна точка представляє один із 50 000 портфелів. Потім ми розраховуємо коефіцієнт Шарпа для кожного портфеля, використовуючи згадану раніше формулу. Коефіцієнт Шарпа слугує показником скоригованої на ризик ефективності, дозволяючи нам визначити, яке алокування портфеля дає вищий коефіцієнт Шарпа. Точки на діаграмі розсіювання з вищим коефіцієнтом Шарпа означають більш оптимальне алокування ваг.

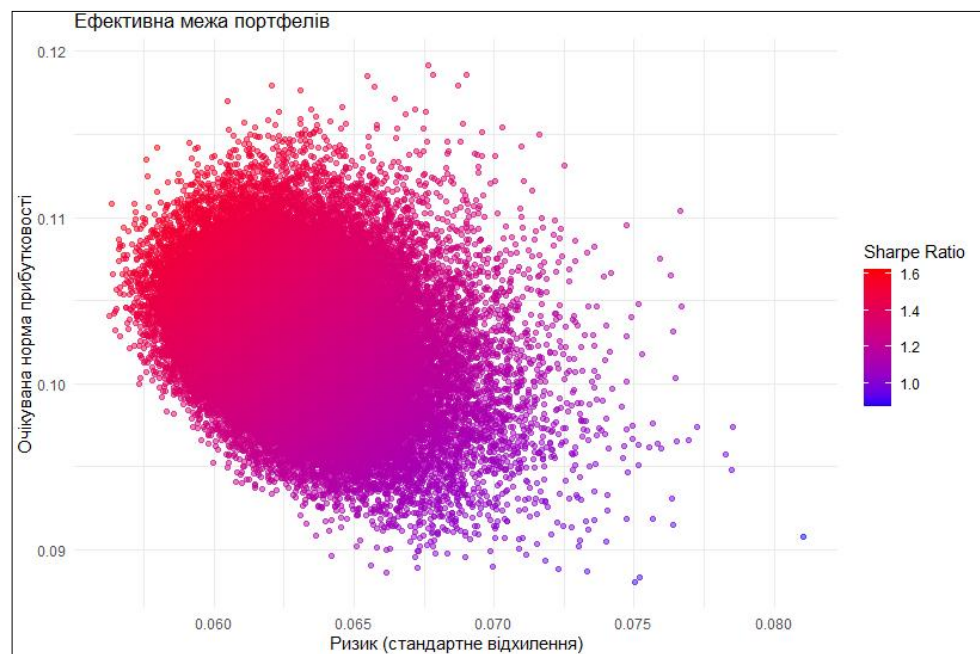


Рис. 2.6. Коефіцієнт Шарпа для 50 тис. згенерованих портфелів

Таким чином, за отриманими результатами можна зробити певні висновки. Графік на рис.2.6. демонструє розподіл портфелів з різними рівнями ризику (стандартного відхилення) та очікуваної норми прибутковості. Чітко помітна ефективна межа у вигляді еліпсоїдного скупчення: портфелі на лівому краю цієї області (найближчі до осі Y) мають мінімальний ризик для заданої прибутковості, що робить їх найбільш оптимальними. Портфелі з правого боку мають вищий рівень ризику за однакову або навіть нижчу норму прибутковості, що робить їх менш привабливими.

Червоні точки вказують на портфелі з найвищим коефіцієнтом Шарпа (~ 1.6 і вище). Це означає, що вони пропонують найкраще співвідношення прибутковості до ризику. Фіолетові та сині точки мають нижчий коефіцієнт Шарпа (близько 1.0), що означає, що вони або надто ризиковані, або пропонують недостатню прибутковість порівняно з їхнім рівнем ризику.

Зі збільшенням ризику (стандартного відхилення) спостерігається зростання очікуваної норми прибутковості — типовий випадок для інвестиційних портфелів. Це свідчить про те, що більш високий ризик супроводжується більшою потенційною прибутковістю. Проте на верхній частині ефективної межі є кілька точок з високою прибутковістю та помірним ризиком, які можуть бути оптимальними для інвесторів.

Найбільш бажані портфелі знаходяться на лівій верхній частині графіка, де ризик відносно низький, а коефіцієнт Шарпа високий (червона область). Ці портфелі пропонують краще співвідношення прибутковості до ризику, що робить їх найбільш привабливими для інвесторів.

Основна маса точок зосереджена у центральній частині графіка (прибутковість близько 9.5–10.5%, ризик ~ 0.065). Це типові портфелі з середньою прибутковістю та помірним рівнем ризику. Деякі портфелі

(праворуч на графіку) мають високий ризик ($\sim 0.075-0.080$) без значного зростання прибутковості, що свідчить про їхню неефективність.

Цей підхід дозволяє нам всебічно оцінити компроміс між ризиком і прибутковістю в різноманітному наборі портфелів, в кінцевому рахунку визначаючи ті, які мають кращу скориговану на ризик ефективність.

Відсотки показують, яку частку кожної з 15 криптовалют займає у найбільш ефективному портфелі. Ось як найбільш ефективно виглядає розподіл наших обраних криптовалют:

BTC (Bitcoin):	13.34%
ETH (Ethereum):	10.46%
BNB (Binance Coin):	13.64%
SOL (Solana):	5.01%
ADA (Cardano):	0.56%
TON (Toncoin):	5.50%
DOGE (Dogecoin):	4.29%
AVAX (Avalanche):	6.95%
NEAR (Near Protocol):	2.73%
MATIC (Polygon):	11.70%
PEPE (Pepe):	1.19%
APT (Aptos):	9.91%
ATOM (Cosmos):	8.61%
ARB (Arbitrum):	0.96%
OP (Optimism):	5.15%

Найбільші відсотки мають: BNB (13.64%), BTC (13.34%), MATIC (11.70%). Ці активи відіграють ключову роль у загальній прибутковості портфеля. Найменші мають ADA (0.56%) і ARB (0.96%), що свідчить про те, що їхній внесок є мінімальним, але вони все ще можуть знизити загальний ризик через диверсифікацію.

Основні метрики портфеля:

1) Очікувана прибутковість: 11.42% на рік. Це середня річна прибутковість, яку можна очікувати за такого розподілу криптовалют.

2) Ризик (стандартне відхилення): 5.8%. Це показує, наскільки сильно може коливатися прибутковість портфеля. Це помірний рівень ризику.

3) Коефіцієнт Шарпа: 1.6249. Це ключова метрика ефективності портфеля, яка показує співвідношення прибутковості до ризику. Значення вище 1.5 вказує на високоефективний портфель.

Цей портфель є оптимальним для інвесторів, які шукають високу прибутковість з помірним ризиком. Основний внесок у прибутковість портфеля роблять BNB, BTC і MATIC, тому ці криптовалюти можуть бути ключовими в інвестиційній стратегії. Криптовалюти з малими вагами (наприклад, ADA та ARB) можуть бути використані для диверсифікації, що допомагає зменшити загальний ризик. Для інвесторів, які хочуть отримати найкраще співвідношення між прибутковістю та ризиком, доцільно зберегти BNB, BTC і MATIC як ключові активи. Для зменшення ризику варто залишити активи з меншими вагами, наприклад, ARB, ADA та PEPE, щоб забезпечити рівномірний розподіл ризику.

РОЗДІЛ 3

РОЗРОБКА МОДЕЛЕЙ ПРОГНОЗУВАННЯ ЦІН КРИПТОВАЛЮТ НА ОСНОВІ ТЕХНІКИ МАШИННОГО НАВЧАННЯ ДЛЯ РЕБАЛАНСУВАННЯ ІНВЕСТИЦІЙНОГО ПОРТФЕЛЮ

3.1 Підготовка даних для прогнозування курсу криптовалют

Перед безпосереднім аналізом, необхідно підготувати дані. Найбільш часто застосовують метод для генерації нового набору даних цін криптовалют Open-High-Low-Close (OHLC) з провідного агрегатора CoinGecko. Діаграми OHLC широко використовуються для ілюстрації руху цін фінансових інструментів (в тому числі і криптовалют) з часом. Після виконання виокремлення даних створюємо новий набір даних, готовий для подальшого аналізу. Аргументами, що задаються користувачем, є: цільовий каталог, ім'я файлу, список монет для включення в набір даних, початкова та кінцева дата отриманих даних. Цей набір даних передається як вхід на наступний етап.

Далі використовуємо методи для генерації тренувального та валідаційного наборів з оригінальних даних. Після виконання розділення даних створює два набори даних у форматі .csv: тренувальний та валідаційний. Тренувальний та валідаційний набори використовуються в процесі тренування моделі. Крім того, валідаційний набір також використовується на етапі прогнозування для прогнозування часових рядів цін на означені монети. Аргументами, що задаються користувачем, є: цільовий каталог, імена файлів, шлях до раніше зібраного набору даних, змінна ціни для розгляду (середня ціна OHLC або просто ціна закриття) та співвідношення для розділення тренувального/валідаційного набору.

Далі використовуємо методи для ефективного попереднього навчання моделей машинного навчання (RNN і GBM) для прогнозування цін на криптовалюту. Виконання цієї команди створює попередньо навчену модель, яка надалі використовується на фінальному етапі прогнозування. Для всіх розглянутих моделей машинного навчання прогноз ціни для заданої користувачем криптовалюти проводиться шляхом спостереження за коливаннями інших високорельованих серій монет. Для попереднього вибору цих ознакових монет користувач може провести попередній аналіз кореляції (детальніше описано в попередньому розділі). Для експериментальної установки потрібен список конфігурацій, заданих користувачем. Ці конфігурації різняться залежно від прийнятої моделі машинного навчання. Для RNN необхідно визначити розмір мережі (кількість прихованих шарів і нейронів), кількість епох навчання та розмір пакету (тобто кількість зразків, оброблених перед оновленням моделі) [39]. Для GBM користувач повинен вказати кількість розгалужень дерев, створених моделлю. Загальні конфігурації для всіх розглянутих моделей: випадкові показники, швидкість навчання та терпіння (тобто кількість "допустимих" послідовних епох/розгалужень дерев без покращення моделі перед раннім зупиненням навчання). Аргументами, що задаються користувачем, є: цільовий каталог, ім'я файлу, шлях до тренувального та валідаційного наборів, модель машинного навчання для використання (LSTM, GRU, XgBoost, LightGBM або CatBoost), цільова монета для прогнозування, список монет для використання як ознакові/прогнозуючі змінні та список конфігурацій для використання експериментальної установки.

Далі відбувається прогнозування майбутніх цін на криптовалюту за допомогою попередньо навченої моделі. Валідаційний набір використовується для підгонки моделі експоненціального згладжування Хольта-Вінтерса [40] та прогнозування часових рядів цін на ознакові

монети для заданого користувачем рівня прогнозування. Прогнозовані ознакові монети потім передаються попередньо навченій моделі для генерації прогнозів цін для вибраної цільової криптовалюти. Аргументами, що задаються користувачем, є: цільовий каталог, ім'я файлу, горизонт прогнозування (кількість майбутніх щоденних цін для прогнозування), шлях до валідаційного набору, шлях до попередньо навченої моделі, модель для використання, цільова монета для прогнозування та список монет для використання як ознакові/прогнозуючі змінні. Ці аргументи повинні бути такими ж, як і ті, що використовуються для процесу попереднього навчання.

Нарешті, використовуємо методи для аналізу кореляцій між цінами на криптовалюти. Вона не є обов'язковою для основного потоку прогнозування цін, але може бути корисною для попереднього вибору високкорельованих криптовалют для використання як ознакові змінні. Аргументами, що задаються користувачем, є: цільовий каталог, імена файлів, шлях до оригінального набору даних, змінна ціни для розгляду (середня ціна OHLC або ціна закриття), часове вікно для використання для обчислень (щоденне, тижневе або місячне) та метод кореляції для використання (Пірсона, Кендалла або Спірмена) [41].

3.2. Навчання та тестування моделей машинного навчання для прогнозування та класифікації

Прийдемо до використання машинного навчання, а саме машинного навчання моделі XGBoost. В додатку А вміщено програмний код для середовища R для машинного навчання моделі на прикладі Bitcoin (BTC).

За результатами навчання отримаємо наступний графік (рис 3.1).



Рис. 3.1. Графік прогнозу ціни на BTC на період 1 рік

Синя лінія відображає історичну ціну BTC з 2013 року до 14 червня 2024 року. Ми бачимо кілька чітких піків і падінь у ціні, які відповідають важливим подіям на криптовалютному ринку (наприклад, булл-рани 2017 та 2021 років, а також великі корекції). Зелена пунктирна лінія представляє прогноз ціни BTC до 14 червня 2025 року, яка відповідно складатиме 42333.47 USDT. Прогноз показує, що ціна BTC, ймовірно, залишиться на високому рівні але зі значними коливаннями у проміжному періоді, що свідчить про значну волатильність.

Зелена лінія показує коливання в діапазоні навколо 40 000–70 000 USDT. Це свідчить про те, що модель врахувала тренди попередніх періодів, але прогноз залишається консервативним. Модель показує стабільність у ціні з певним великими коливанням, що на жовтень 2024 року має підтвердження у пониженні ціни BTC до 49000 USDT наприкінці літа 2024 року. А отже отриманий графік демонструє, що ціна BTC до середини 2025 року залишатиметься на високому рівні з помірною волатильністю. Модель XGBoost змогла вловити попередні

тенденції, але майбутні ціни можуть залежати від непередбачуваних подій на ринку криптовалют. Зокрема, доля криптовалют часто пов'язується із виборами президента із-за заяв Данальда Трампа.

Всі інші криптовалюти з нашого портфелю так само опрацьовуємо за допомогою машинного навчання. Нижче ще приведемо приклад моделювання ETH (рис. 3.2). Як бачимо з графіку, прогнозується падіння ціни з наступним підйомом і стабілізацією. Дана закономірність трапляється на більшості прогнозних графіках обраних криптовалют, і є ознакою того що купівлю треба відкласти до падіння цін. І це типова картина, адже як би ми не хотіли диверсифікувати наші активи але специфіка криптовалют полягає в значній залежності всіх від коливання біткоїна.




Рис. 3.1. Графік прогнозу ціни на ETH на період 1 рік

Але, для експерименту сформуємо запит на прогнозну ціну через рік від останньої дати в наборі даних. За результатами розрахунків по нашій моделі ми отримаємо наступні показники (таблиця 3.1):

Таблиця 3.1.

Прогнозні ціни криптовалют інвестиційного портфелю через рік після імітаційної купівлі за моделлю

Криптовалюти	Ціна 14.06.2024	Проміжна ціна 27.10.2024 для моніторингу дієвості	Відсоток зміни ціни за період моніторингу	Прогнозна ціна на 15.06.2025 за XGBoost	Відсоток зростання ціни за прогнозом XGBoost
BTC	66700.32	67620.18	1.38	42333.47	-36.53
ETH	3465.32	2492.24	-28.08	3489.49	0.70
BNB	599.16	586.61	-2.09	595.56	-0.60
ADA	0.41	0.34	-17.41	0.43	3.40
APT	7.69	9.15	19.04	8.06	4.90
ARB	0.91	0.52	-43.51	0.94	3.24
ATOM	7.11	4.39	-38.29	7.43	4.51
AVAX	30.30	25.68	-15.25	31.45	3.79
DOGE	0.14	0.14	0.65	0.14	1.36
MATIC	0.59	0.33	-44.18	0.64	7.62
NEAR	5.58	4.30	-22.93	6.22	11.45
OP	2.00	1.59	-20.52	2.08	4.18
SOL	147.23	176.03	19.56	149.93	1.83
PEPE	0.00	0.00	-47.74	0.00	0.88
TON	8.17	4.94	-39.54	7.23	-11.52

В таблиці також вміщені проміжні дані на 27.10.2024 для перевірки тренду цін. Як видно з таблиці, через рік, за моделлю XGBoost, Bitcoin втратив у ціні більше 35%, також знизиться суттєво ціна на TON та частково на BNB. Всі інші криптовалюти дадуть різну величину приросту. Скоріш за все, на момент настання одного року портфель буде збитковим, оскільки в ньому чи не основна роль відводиться біткоїну.

3.3. Оцінка інвестиційного портфелю щодо прогнозних цін та його оптимізація

За результатами машинного навчання та виділення прогнозної моделі, можна чітко визначити що визначена в наборі даних дата не є зручною точкою входу в інвестицію оскільки очікується значне падіння цін на осінньо-зимово-весняний період. Але, і в такому разі ми можемо перевірити наш портфель за моделлю Марковіца, імітуючи закупівлю криптовалют 14 червня 2024 року по відповідним ринковим цінам на загальну суму 1000000 USDT. Показники розподілу за портфелем та прогнозні ціни і суми за моделлю машинного навчання відображені в таблиці 3.2.

Таблиця 3.2.

Прогноз дохідності портфелю в проміжний період (реальні ціни) та прогнозний (ціни за моделлю машинного навчання)

Криптовалюти	Частка в портфелі за моделлю Марковіца, %	Вартість активів портфелю за моделлю Марковіца в	Кількість монет в портфелі	Вартість активів портфелю в проміжний період на	Вартість активів портфелю на 15.06.2025 за
BTC	13.34	133400	2.00	135240	84666.5
ETH	10.46	104600	30.18	75227.8	105330
BNB	13.64	136400	227.65	133544	135581
ADA	0.56	5600	13607.43	4625.16	5790.5
APT	9.91	99100	12892.42	117966	103951
ARB	0.96	9600	10528.39	5423.18	9910.9
ATOM	8.61	86100	12102.62	53130.5	89980
AVAX	6.95	69500	2293.59	58899.3	72135.7
DOGE	4.29	42900	304298.48	43180	43484.3
MATIC	11.70	117000	198039.91	65313.6	125910
NEAR	2.73	27300	4893.01	21039.9	30426.7
OP	5.15	51500	25742.53	40930.6	53654.7
SOL	5.01	50100	340.27	59898.3	51016
PEPE	1.19	11900	1053097345.13	6219.28	12005.3
TON	5.50	55000	6731.19	33252.1	48661.4
	Сума:	1000000	Сума:	853889	972503
			Втрати,%	14.61	2.75

Тут ми можемо спостерігати що наш портфель збитковий на 2.75%, і знову ж таки це пов'язано із падінням ціни на біткоїн який був закуплений по майже найвищій ціні після халвінгу. Також, з таблиці ми бачимо падіння курсу TON, і це цілком закономірне явище пов'язане із розквітом "тапалок" в мережі TON, частина з яких генерує власні токени такі як HamsterCombat, Dogs,Cats тощо. Тако TON є основною криптовалютою в Telegram-гаманцях. Таким чином, ми розглядаємо таблицю зміни навчання моделі капіталізації нашого портфелю лише як імітацію результативності при досить умовній точці входу в ринок без попереднього дослідження. За результатами машинного навчання моделі ми можемо визначити прогнозовану дату входу в ринок по кожній криптовалюти на "низах". Згідно проміжного моніторингу на жовтень 2024 року, наша модель машинного навчання досить вдало спрогнозувала падіння цін що ми також бачимо по показниках нашої таблиці.

Також, варто сказати, що при використанні спотової торгівлі ми можемо використати варіант стейкінгу (депозиту) на біржі. Хоча відсоткові ставки досить низькі але всеодно вони дають приріст кількості монет що пропорційно збільшує і потенційний прибуток при рості. Варіант прибутковості стейкінгу ми відобразили у таблиці 3.3. Загальний відсоток приросту вартості портфелю склав лише 0.56 % але це при умові збитковості портфелю за вказаною вище імітацією через рік після входу в ринок.

Також, для зменшення ризику можна використати параметр очікуваної прибутковості портфелю, який склав за моделлю Марковіца 11,42%. Тобто, на рівні такого зростання ціни можна ставити автоматичний продаж. Навіть при абсолютному падінні цін у нашій модельній ситуації, на період моніторингу у жовтні 2024 року, Solana зробила приріст ціни на 31,75% вже 29 липня, тобто через 1,5 місяці від нашого входу в ринок. Це вже б склало 1,5% приросту вартості

портфелю. Так само, приріст ціни на AVAX досягнув відмітки +10% вже 21 липня. ADA досягала приросту +11,04% вже 17 липня. АРТ досяг позначки в +46,22% 22 жовтня. Враховуючи майже 10% АРТ в портфелі, то при автоматичному продажу при досягненні зростання ціни на 10-11% ми вже б отримали +1% прибутку.

Таблиця 3.3.

Параметри стейкінгу криптовалют інвестиційного портфеля

Криптовалюти	кількість монет	Відсоткова ставка стейкінгу	Кількість монет через рік	Вартість криптовалют в портфелі
BTC	2.00	0.28	2.01	84904.34
ETH	30.18	1.36	30.59	106754.73
BNB	227.65	0.18	228.06	135822.81
ADA	13607.43	0.33	13652.41	5809.65
ART	12892.42	0.25	12924.69	104211.53
ARB	10528.39	0.05	10533.66	9915.86
ATOM	12102.62	0.86	12207.15	90757.11
AVAX	2293.59	1.25	2322.44	73043.15
DOGE	304298.48	0.10	304602.93	43527.76
MATIC	198039.91	0.00	198039.91	125909.82
NEAR	4893.01	0.25	4905.26	30502.86
OP	25742.53	0.04	25752.83	53676.11
SOL	340.27	0.61	342.35	51327.70
PEPE	1053097345.13	9.06	1152950641.87	13143.64
TON	6731.19	0.43	6760.20	48871.08
			Сума	978178.128
			Прибуток від стейкінгу	5675.12777

Таким чином, за результатами проведених досліджень можна зробити певні висновки щодо формування торгової стратегії криптовалютами:

1. Досліджуємо моделі зміни цін за допомогою машинного навчання по обраним криптовалютам.

2. Обираємо точку входу в ринок за результатами машинного навчання

3. За моделлю Марковіца формуємо торговий портфель, в який відбираємо монети на основі ринкової капіталізації та результатів машинного навчання.

4. Додатково використовуємо стейкінг закуплених криптовалют для збільшення прибутку

5. За отриманим значенням очікуваного прибутку портфелю, для зменшення ризиків, можемо виставляти автоматичні продажі криптоактивів при досягненні певної ціни.

ВИСНОВКИ

1. Криптовалюти суттєво змінили сучасний фінансовий ландшафт, надаючи інвесторам нові можливості, але водночас супроводжуючи інвестиції високими ризиками. Завдяки технології блокчейн криптовалюти забезпечують безпечні, децентралізовані транзакції без потреби в центральних установах. Попри це, ринок криптовалют характеризується надзвичайною волатильністю, що робить прогнози складними, а інвестиції – ризикованими. Інструменти на основі машинного навчання та штучного інтелекту допомагають інвесторам приймати рішення в умовах невизначеності.

Bitcoin та Ethereum залишаються ключовими криптовалютами, які формують ринок та слугують індикаторами для інших цифрових активів. Bitcoin є засобом збереження вартості, а Ethereum виділяється своєю програмованістю, яка сприяє розвитку децентралізованих додатків та нових фінансових сервісів. Незважаючи на обмежене використання криптовалют у роздрібних платежах, вони набули популярності як спекулятивний актив, приваблюючи інвесторів із високим апетитом до ризику.

2. Фінансові ринки є складними структурами, де торгують різноманітними фінансовими інструментами. Існують різні види аналізу для прийняття рішень на фінансових ринках: фундаментальний, технічний та кількісний. Фундаментальний аналіз зосереджується на оцінці економічних показників, тоді як технічний аналіз базується на історичних даних про ціни та обсяги торгів. Кількісний аналіз застосовує математичні та статистичні методи для прогнозування ринкових змін, зокрема аналіз часових рядів.

Інноваційні методи машинного навчання, такі як нейронні мережі та машини опорних векторів (SVM), набувають дедалі більшого значення для прогнозування даних на фінансових ринках. Завдяки своїй

універсальності та ефективності ці методи не лише допомагають у виявленні тенденцій, але й знаходять застосування в інших галузях.

Для прогнозування цін криптовалют ефективними виявились два сімейства моделей машинного навчання – градієнтні бустингові машини (GBM) та рекурентні нейронні мережі (RNN). GBM продемонстрували високу точність у передбаченні як стабільних, так і нестабільних тенденцій цін, що робить їх придатними для аналізу довгострокових трендів. Зокрема, моделі XGBoost, LightGBM та CatBoost відзначаються високою швидкістю навчання, масштабованістю та точністю.

RNN, у свою чергу, краще підходять для роботи з послідовними даними завдяки здатності враховувати попередні етапи обробки інформації. Проте, ці мережі стикаються з проблемами нестабільності градієнтів, що ускладнює їхню ефективність для прогнозування на основі тривалих часових рядів. Незважаючи на ці обмеження, RNN продовжують розвиватися та знаходять застосування в різних сферах. Таким чином, поєднання GBM та RNN дозволяє підвищити точність прогнозування цін криптовалют, забезпечуючи всебічний аналіз даних.

3. Криптовалюти стають дедалі популярнішими як альтернативні інвестиційні активи через їх потенціал для високої прибутковості та можливість диверсифікації портфелів. Проте висока волатильність і нестабільність цін роблять їх ризикованими активами. Для ефективного включення криптовалют до інвестиційних портфелів важливо враховувати не лише прибутковість і ризик, але й ліквідність активів, що є ключовим фактором для створення збалансованих портфелів. Аналіз історичних даних показує значні коливання цін, як у випадку з біткойном, що демонструє потенціал для великих прибутків, але також і високі ризики. Успішне інвестування в криптовалюти потребує комплексного підходу з використанням різних моделей оптимізації портфелів, таких як LIBRO, які враховують ліквідність і привабливість активів.

У дослідженні використано модель Марковіца, яка дозволяє сформувати оптимальні інвестиційні портфелі, мінімізуючи ризик та максимізуючи очікувану прибутковість. Основна ідея цієї моделі полягає у диверсифікації активів, що знижує загальний ризик портфеля. Завдяки обчисленням, проведеним у середовищі R, дослідження включає аналіз добової та річної прибутковості, розрахунок коваріаційної матриці та визначення ефективної межі для оптимізації портфелів.

Ефективна межа дозволяє знайти такі комбінації активів, які забезпечують максимальну прибутковість на одиницю ризику або мінімальний ризик для заданої прибутковості. У рамках дослідження використовувався також коефіцієнт Шарпа, який вимірює ефективність портфеля з урахуванням ризику. Вищий коефіцієнт Шарпа свідчить про кращу скориговану на ризик ефективність портфеля, що робить його більш привабливим для інвесторів.

4. У цьому дослідженні проведено аналіз динаміки цін та прибутковості 15 криптовалют за допомогою сучасних фінансових методів і моделей. На основі графіків та статистичних вимірювань було встановлено, що Bitcoin (BTC) та Ethereum (ETH) демонструють найбільшу стабільність серед обраних криптовалют, хоча вони все ще зазнають істотних коливань. Інші криптовалюти, такі як Optimism (OP) і PERE, відзначаються високою волатильністю, що вказує на підвищений рівень ризику для інвесторів.

Проведена кореляційна матриця показала сильний позитивний зв'язок між основними криптовалютами, такими як BTC, ETH і SOL, що свідчить про узгодженість їхніх цінових коливань. У той же час деякі криптовалюти, наприклад, TON та ARB, продемонстрували низький рівень кореляції з іншими активами, що вказує на їхню незалежну ринкову динаміку.

Загалом, оптимізація портфелів проводилася за моделлю Марковіца з використанням коефіцієнта Шарпа для вибору найефективніших портфелів. Розрахунки показали, що найкращий портфель досягає річної прибутковості в 11,42% зі стандартним відхиленням 5,8%, що є помірним рівнем ризику. Основний внесок у прибутковість забезпечують BNB, BTC та MATIC, які отримали найбільші ваги в портфелі. Криптовалюти з меншими вагами, такі як ADA та ARB, додають диверсифікаційної вигоди, знижуючи загальний ризик портфеля.

5. Нами було використано модель машинного навчання XGBoost для прогнозування цін криптовалют. Результати моделювання показали, що ціни BTC та інших криптовалют залишатимуться високими, але зі значними коливаннями, що свідчить про їхню високу волатильність. Прогноз підтвердив, що ціна BTC до 14 червня 2025 року складатиме 42 333,47 USDT, однак варто очікувати проміжних падінь і підйомів. Це підкреслює важливість вибору оптимальної точки входу для зменшення ризиків і підвищення прибутковості.

Аналіз показав, що ринок криптовалют залишається залежним від коливань біткоїна, що ускладнює диверсифікацію портфеля. Падіння вартості Bitcoin після червня 2024 року негативно вплинуло на загальну прибутковість портфеля. У відповідь на ці виклики запропоновано використання стейкінгу для часткового покриття збитків та збільшення кількості монет. Хоча очікуваний приріст від стейкінгу був незначним (0,56%), він все ж може підвищити прибутковість портфеля під час зростання ринку. При цьому, незважаючи на загальне падіння ринку, окремі криптовалюти, такі як Solana (SOL), Avalanche (AVAX), ADA та Aptos (APT), продемонстрували суттєвий короткостроковий приріст. Це свідчить про можливість отримання прибутку за умови вчасних продажів.

Отже, успішне управління портфелем криптовалют потребує комплексного підходу: поєднання машинного навчання для вибору оптимальної точки входу, використання стейкінгу для збільшення прибутковості та застосування моделі Марковіца для оптимізації ризиків. Автоматизація продажів за наперед визначеними цінами може також допомогти знизити ризики та підвищити ефективність інвестиційної стратегії.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Hameed B. I. Blockchain and Cryptocurrencies Technology: a survey. *JOIV : International Journal on Informatics Visualization*. 2019. Vol. 3, no. 4. URL: <https://doi.org/10.30630/joiv.3.4.293> (date of access: 26.10.2024).
2. Cryptocurrency price forecasting – A comparative analysis of ensemble learning and deep learning methods / A. Bouteska et al. *International Review of Financial Analysis*. 2024. Vol. 92. P. 103055. URL: <https://doi.org/10.1016/j.irfa.2023.103055> (date of access: 28.10.2024).
3. Chaudhary D., Saroj S. K. Cryptocurrency Price Prediction Using Supervised Machine Learning Algorithms. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*. 2023. Vol. 12. P.431-490. URL: <https://doi.org/10.14201/adcaij.31490> (date of access: 26.10.2024).
4. Gudavalli H. N., Kancherla K. V. R. *Predicting Cryptocurrency Prices with Machine Learning Algorithms: A Comparative Analysis*. URL: <https://bth.diva-portal.org/smash/get/diva2:1778251/FULLTEXT03.pdf> (date of access: 26.10.2024).
5. Some stylized facts of the Bitcoin market / A. F. Bariviera et al. *Physica A: Statistical Mechanics and its Applications*. 2017. Vol. 484. P. 82–90. URL: <https://doi.org/10.1016/j.physa.2017.04.159> (date of access: 26.10.2024).
6. Bitcoin BTC Price. *CoinGecko*. URL: <https://www.coingecko.com/en/coins/bitcoin>.
7. Kajtazi A., Moro A. The role of bitcoin in well diversified portfolios: A comparative global study. *International Review of Financial Analysis*. 2019. Vol. 61. P. 143–157. URL: <https://doi.org/10.1016/j.irfa.2018.10.003> (date of access: 26.10.2024).

8. Дізнайтеся все про блокчейн і криптовалюту | Binance Academy. *Binance Academy*. URL: <https://academy.binance.com/uk> (дата звернення: 28.10.2024).
9. Blockchain, business and the fourth industrial revolution: Whence, whither, wherefore and how? / D. Kimani et al. *Technological Forecasting and Social Change*. 2020. Vol. 161. P. 120254. URL: <https://doi.org/10.1016/j.techfore.2020.120254> (date of access: 28.10.2024).
10. Kucheryavenko M. P., Dmytryk O. O., Golovashevych O. O. CRYPTOCURRENCIES: DEVELOPMENT, FEATURES AND CLASSIFICATION. *Financial and credit activity: problems of theory and practice*. 2019. Vol. 3, no. 30. P. 371–374. URL: <https://doi.org/10.18371/fcaptp.v3i30.179737> (date of access: 26.10.2024).
11. Про Ethereum (ETH). *Bybit*. URL: <https://www.bybit.com/uk-UA/coin-price/ethereum/> (дата звернення: 26.10.2024).
12. Ethereum official site [Electronic resource]. Available at : <https://www.ethereum.org/beginners>.
13. TradingView – Track All Markets. *TradingView*. URL: <https://tradingview.com/> (date of access: 28.10.2024).
14. Kuo Chuen D. L., Guo L., Wang Y. Cryptocurrency: A New Investment Opportunity?. *The Journal of Alternative Investments*. 2017. Vol. 20, no. 3. P. 16–40. URL: <https://doi.org/10.3905/jai.2018.20.3.016> (date of access: 28.10.2024).
15. Foundations of Financial Markets and Institutions. / R. L. Moy et al. *The Journal of Finance*. 1994. Vol. 49, no. 4. P. 1521. URL: <https://doi.org/10.2307/2329197> (date of access: 28.10.2024).
16. *Financial Stability Board - Promoting global financial stability through strong financial sector policies*. URL: <http://www.fsb.org/wp-content/uploads/P011117.pdf> (дата звернення: 28.10.2024).

17. Levinson M. *Economist Guide to Financial Markets 7th Edition*. Profile Books Limited, 2018. 304 p.
18. Kidwell D. S. *Financial Institutions, Markets, and Money*. Wiley & Sons, Incorporated, John, 2016.
19. Akansu A. N., Torun M. U. *Primer for Financial Engineering: Financial Signal Processing and Electronic Trading*. Elsevier Science & Technology Books, 2015.
20. A literature review of technical analysis on stock markets / R. T. Farias Nazário et al. *The Quarterly Review of Economics and Finance*. 2017. Vol. 66. P. 115–126. URL: <https://doi.org/10.1016/j.qref.2017.01.014> (date of access: 28.10.2024).
21. A Hybrid Traditional and Machine Learning-Based Stacking-Based Ensemble Forecasting Approach for Coal Price Prediction / A. M. Yaşın et al. *Indonesian Journal of Artificial Intelligence and Data Mining*. 2024. Vol. 7, no. 2. P. 436. URL: <https://doi.org/10.24014/ijaidm.v7i2.30547> (date of access: 28.10.2024).
22. Молікевич Р.С. Використання машинного навчання для прогнозування цін криптовалют. *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.) [Електронний ресурс] / [упоряд: А. Яцишин, В. Матусевич, В. Коваленко]. Київ : УкрІНТЕІ, 2024. С. 559–562.*
23. Treleaven P., Galas M., Lalchand V. Algorithmic trading review. *Communications of the ACM*. 2013. Vol. 56, no. 11. P. 76–85. URL: <https://doi.org/10.1145/2500117> (date of access: 28.10.2024).
24. Dingli A., Fournier K. S. Financial Time Series Forecasting – A Deep Learning Approach. *International Journal of Machine Learning and Computing*. 2017. Vol. 7, no. 5. P. 118–122.

URL: <https://doi.org/10.18178/ijmlc.2017.7.5.632> (date of access: 28.10.2024).

25. Tay F. E. H., Cao L. Application of support vector machines in financial time series forecasting. *Omega*. 2001. Vol. 29, no. 4. P. 309–317. URL: [https://doi.org/10.1016/s0305-0483\(01\)00026-3](https://doi.org/10.1016/s0305-0483(01)00026-3) (date of access: 28.10.2024).

26. De Rosa P., Felber P., Schiavoni V. CryptoAnalytics: Cryptocoins price forecasting with machine learning techniques. *SoftwareX*. 2024. Vol. 26. P. 101-163. URL: <https://doi.org/10.1016/j.softx.2024.101663> (date of access: 27.10.2024).

27. An Introduction to Statistical Learning / G. James et al. New York, NY : Springer New York, 2013. URL: <https://doi.org/10.1007/978-1-4614-7138-7> (date of access: 27.10.2024).

28. Gopal S., Ramasamy M. Hybrid multiple structural break model for stock price trend prediction. *The Spanish Review of Financial Economics*. 2017. Vol. 15, no. 2. P. 41–51. URL: <https://doi.org/10.1016/j.srfe.2017.02.002> (date of access: 28.10.2024).

29. Kajtazi A., Moro A. The role of bitcoin in well diversified portfolios: A comparative global study. *International Review of Financial Analysis*. 2019. Vol. 61. P. 143–157. URL: <https://doi.org/10.1016/j.irfa.2018.10.003> (date of access: 26.10.2024).

30. Trimborn S., Härdle W. K. CRIX an Index for cryptocurrencies. *Journal of Empirical Finance*. 2018. Vol. 49. P. 107–122. URL: <https://doi.org/10.1016/j.jempfin.2018.08.004> (date of access: 26.10.2024).

31. Aljinović Z., Marasović B., Šestanović T. Cryptocurrency Portfolio Selection—A Multicriteria Approach. *Mathematics*. 2021. Vol. 9, no. 14. P. 1677. URL: <https://doi.org/10.3390/math9141677> (date of access: 26.10.2024).

32. Liu W. Portfolio diversification across cryptocurrencies. *Finance Research Letters*. 2019. Vol. 29. P. 200–205. URL: <https://doi.org/10.1016/j.frl.2018.07.010> (date of access: 26.10.2024).
33. Ciaian P., Rajcaniova M., Kancs d. The economics of BitCoin price formation. *Applied Economics*. 2015. Vol. 48, no. 19. P. 1799–1815. URL: <https://doi.org/10.1080/00036846.2015.1109038> (date of access: 28.10.2024).
34. Trimborn S., Li M., HHrdle W. K. Investing with Cryptocurrencies - A Liquidity Constrained Investment Approach. *SSRN Electronic Journal*. 2017. URL: <https://doi.org/10.2139/ssrn.2999782> (date of access: 26.10.2024).
35. Enhancing Cryptocurrency Price Forecasting by Integrating Machine Learning with Social Media and Market Data / L. Belcastro et al. *Algorithms*. 2023. Vol. 16, no. 12. P. 542. URL: <https://doi.org/10.3390/a16120542> (date of access: 28.10.2024).
36. Markowitz H.M. Portfolio Selection. *The Journal of Finance*. 1952. Vol. VII № 1. DOI : 10.М2307/2975974
37. Yi Y. Research on cryptocurrency portfolio based on Markowitz model. *Highlights in Business, Economics and Management*. 2024. Vol. 32. P. 237–254. URL: <https://doi.org/10.54097/6q50bk41> (date of access: 26.10.2024).
38. Олійник В.М., Фролов С.М., Лещенко Ю.І. Деякі аспекти оптимізації портфеля фінансових інструментів. Маркетинг і менеджмент інновацій. 2012. № 1. С. 140–147. URL : http://nbuv.gov.ua/UJRN/Mimi_2012_1_17
39. Deep Learning-Based Bitcoin Price Forecasting Using Neural Prophet / T. R. Noviandy et al. *Ekonomikalia Journal of Economics*. 2023. Vol. 1, no. 1. P. 19–25. URL: <https://doi.org/10.60084/eje.v1i1.51> (date of access: 28.10.2024).

40. Chatfield C. The Holt-Winters Forecasting Procedure. *Applied Statistics*. 1978. Vol. 27, no. 3. P. 264.
URL: <https://doi.org/10.2307/2347162> (date of access: 28.10.2024).

41. Chen P., Popovich P. Correlation. 2455 Teller Road, Thousand Oaks California 91320 United States of America : SAGE Publications, Inc., 2002. URL: <https://doi.org/10.4135/9781412983808> (date of access: 28.10.2024).