

УДК [330.322.54+336.741.24-028.27]:004.942 DOI: https://doi.org/10.31521/modecon.V48(2024)-11

Молікевич Р.С., кандидат географічних наук, доцент, доцент кафедри географії та екології, Херсонський державний університет, м. Херсон, Україна

ORCID ID: 0000-0002-6577-503X

e-mail: molikevych@gmail.com

Стратегія формування інвестиційного портфеля криптовалют з використанням моделей машинного навчання

Анотація. У даному дослідженні представлено стратегічну модель формування інвестиційного портфеля із використанням моделей машинного навчання та методів оптимізації. Зокрема, застосовано модель машинного навчання градієнтного бустингу (XGBoost) для прогнозування цін криптовалют і вибору точки входу в ринок. На основі моделі виявлено високу волатильність криптовалют та загальну залежність від ринкових коливань BTC. За моделлю Марковіца було сформовано інвестиційний портфель з найкращим прогнозованим співвідношенням прибутковості та ризику. До портфеля було обрано 15 криптовалют, які мають високу капіталізацію, але різні рівні волатильності й ризикованості. Точкою входу в ринок умовно було обрано останні цінові дані на момент проведення аналізу. Через 7 місяців від імітаційної купівлі, інвестиційний портфель продемонстрував зростання на майже 50 відсотків. Зазначені результати підтверджують дієвість відповідного аналізу та оптимальний рівень диверсифікації

Ключові слова: невизначеність зовнішнього середовища, економічні стратегії, рівень невизначеності, адаптаційні стратегії, економічний ризик

Molikevych Roman, PhD (Economic and Social Geography), Associate Professor at the Department of Geography and Ecology, Kherson State University, Kherson, Ukraine

A Strategy for Building a Cryptocurrency Investment Portfolio Using Machine Learning Models

Abstract. Introduction. This study uses machine learning models and optimization methods to present a strategic model for building a cryptocurrency investment portfolio. Specifically, the machine learning model XGBoost (Gradient Boosting) was used to predict cryptocurrency prices and identify optimal market entry points. The model revealed high cryptocurrency volatility and significant dependence on BTC market fluctuations. Based on Markowitz's model, an investment portfolio was constructed to achieve the best predicted risk-return ratio. The portfolio consisted of 15 cryptocurrencies with high market capitalization but varying levels of volatility and risk. The market entry point was set based on the most recent price data available during the analysis. Seven months after the simulated purchase, the portfolio grew by nearly 50%. These results confirm the effectiveness of the proposed analysis and the optimal level of diversification.

Purpose. The purpose of this study is to develop a methodology for constructing a cryptocurrency investment portfolio using machine learning models and to evaluate the effectiveness of the portfolio based on simulated market performance.

Results. The study used the XGBoost price forecasting model and identified significant correlations between cryptocurrency prices and BTC market dynamics. The Markowitz model generated a diversified cryptocurrency portfolio that showed significant growth under simulated trading conditions. The results confirm the viability of using machine learning and optimization methods for cryptocurrency portfolio management.

Conclusions. Combining machine learning models, such as XGBoost, with portfolio optimization methods, such as Markowitz's model, provides a powerful tool for effective decision-making in cryptocurrency investing. This approach allows investors to more accurately predict market dynamics, identify optimal entry points, and construct portfolios that balance risk and return. The use of the Sharpe ratio further enhances portfolio performance evaluation by quantifying the trade-off between volatility and profitability. In addition, including cryptocurrencies with varying levels of volatility and capitalization ensures a well-diversified portfolio that can withstand market fluctuations. The study demonstrates that a machine learning-driven strategy, combined with robust financial optimization techniques, mitigates risk and captures significant growth opportunities in the highly volatile cryptocurrency market. These findings underscore the value of adopting data-driven methods for portfolio management, and the potential to improve investment outcomes in emerging digital asset markets.

Keywords: Cryptocurrencies; machine learning; XGBoost; Markowitz model; price forecasting; investment portfolio; volatility; portfolio optimization; Sharpe ratio.

JEL Classification: G11; G17; C45; C61.

¹Стаття надійшла до редакції: 09.12.2024

Received: 09 December 2024

Постановка проблеми. Сучасний фінансовий світ характеризується високою динамічністю та інноваційністю. В останні роки криптовалюти змінили уявлення людей про фінансові транзакції та переформували традиційну фінансову індустрію. Поява криптовалют відкрила перед інвесторами нові можливості для успішних інвестицій. Волатильність, децентралізованість та технологічна основа криптовалют 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.

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 [11]. 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 послідуєчого падіння ціни знову [4]. Але вже 5 грудня 2024 року вартість Bitcoin перетнула позначку у \$100 000, і це вже є найвизначнішою подією на ринку криптовалют за увесь час. Це показує, що інвестування в криптовалюту має потенціал для отримання значних прибутків, але також несе ризик значних втрат через свою волатильність.

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. Саме тому, 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.

Аналіз останніх досліджень та публікацій. Останні роки стали свідками активного вивчення ролі криптовалют в інвестиційних портфелях. Науковці досліджували як вплив окремих цифрових валют, зокрема Bitcoin [9], на портфелі, що включають традиційні активи, так і ефективність цілих портфелів криптовалют, представлених індексами на кшталт CRIX [13]. Більшість досліджень підтверджують позитивний вплив криптовалют на співвідношення ризику та прибутковості інвестицій [2].

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 [10]. Існують різні виграшні стратегії залежно від спостережуваного періоду та вибірки.

У дослідженні Сімона Трімборна було відібрано криптовалюту до портфелів у поєднанні з акціями. Враховуючи високу волатильність і відносно низьку ліквідність, замість стандартної моделі середньоквадратичного відхилення вони пропонують метод LIBRO (оптимізація ризик-прибутковості з обмеженням ліквідності) [14, 5]. 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 криптовалюту [8]. 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 прибутковості криптовалют.

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 [12]. 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.

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 [9]. 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 [3]. 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.

Формулювання цілей дослідження. Метою даного дослідження є тестування стратегії використання моделей машинного навчання для прогнозування динаміки цін криптовалют при формуванні інвестиційного портфеля.

Виклад основного матеріалу дослідження. 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, й 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.

У 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. 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 портфеля шляхом диверсифікації інвестицій між активами, що дозволяє інвесторам вибрати 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 [15].

Для вивчення портфелів криптовалют ми поєднуємо модель Марковіца з техніками аналізу даних, щоб сформувані наш дослідницький метод. 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 [1].

Також використовувався коефіцієнт Шарпа. 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 покриває 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.

Для того, щоб дослідити загальну тенденцію зміни цін на криптовалюти, ми використали часові дані цін криптовалют до 14 червня 2024 року, що і вважалось точкою входу в ринок при подальшій імітації

портфеля. Аналіз базується на даних про щоденну прибутковість, отриманих з фінансового вебсайту Coingecko [6]. 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), Polygon (MATIC), Aptos (APT).

Вибір криптовалют засновувався на попередньому фундаментальному аналізі, а також моделі машинного навчання XGBoost, яка забезпечувала прогноз подальших цін на активи як інструмент зниження інвестиційного ризику, прогнозу дохідності та ребалансування портфеля. За результатами навчання нашої моделі отримуємо наступний графік (рис. 1).

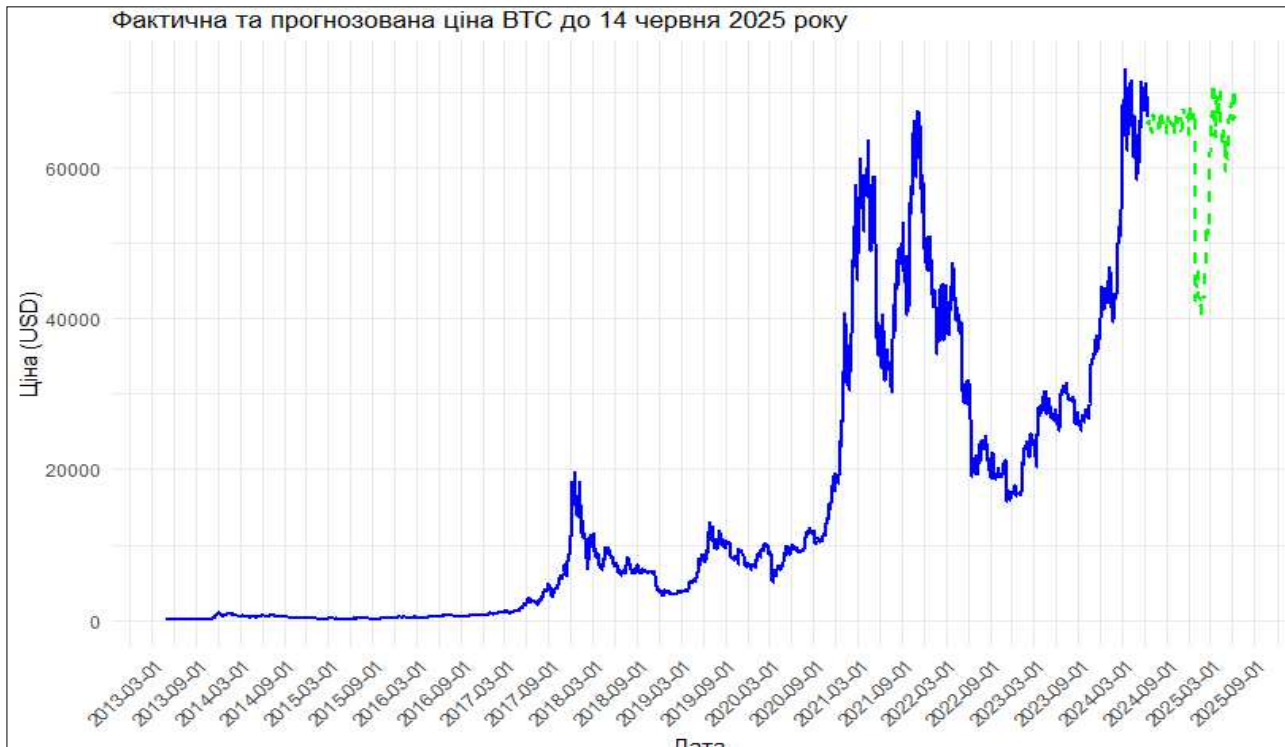


Рисунок 1 – Графік прогнозу ціни на BTC на період 1 рік

Джерело: сформовано автором

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, станом на зараз, ціна BTC перетнула позначку у \$100 тис. на фоні виборів президента Дональда Трампа, якого часто називають крипто-президентом вказуючи на його лояльність до нового ринку.

Всі інші криптовалюти з нашого портфеля так само опрацьовуємо за допомогою машинного навчання. Таким чином, завдяки моделі машинного навчання ми отримуємо технічну впевненість у стабільності прогнозованих цін, а також прогнозуємо найбільш вдалий час для входу у ринок на етапі просадки.

При аналізі обраних криптовалют також було проведено додатковий технічний аналіз, наприклад

box plot-графік (рис. 2), за яким можна зробити більш за останні 3 роки послідовні висновки відносно зміни цін криптовалют

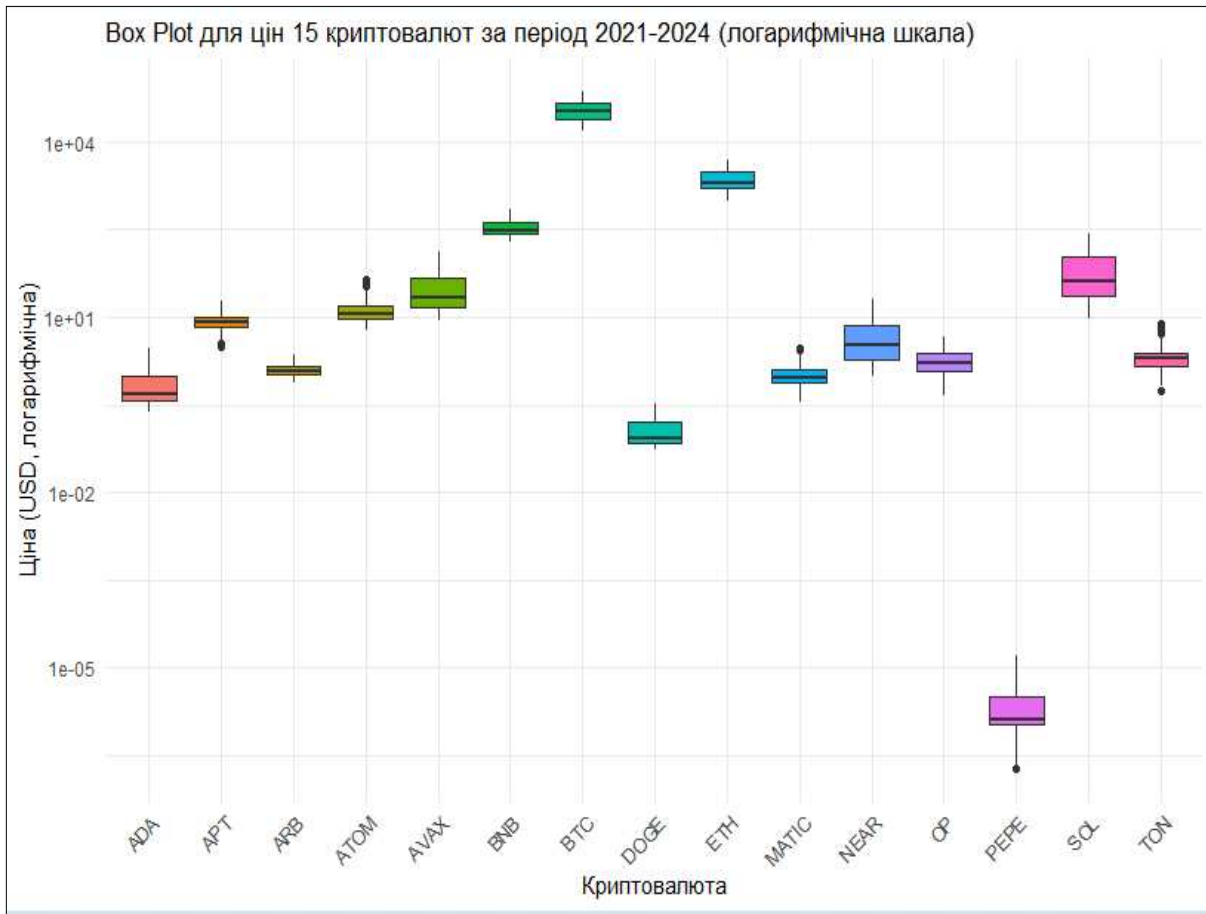


Рисунок 2 – Тенденції обраних криптовалют

Джерело: сформовано автором

Нами було проаналізовано гістограми розподілу щоденної прибутковості для обраних криптовалют (рис. 3). Кожен графік демонструє як часто спостерігаються різні значення прибутковості за вказаний період. За графіками також можна зробити узагальнені висновки:

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.

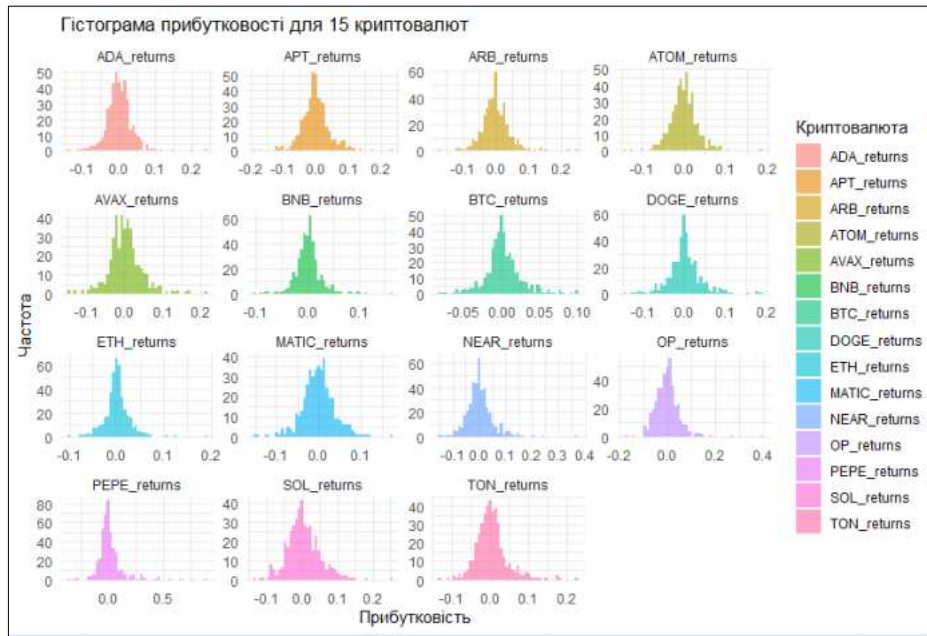


Рисунок 3 – Графік прибутковості обраних криптовалют

Джерело: сформовано автором

Також, нами було виконано коваріаційну матрицю для криптовалют (рис. 4). 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).

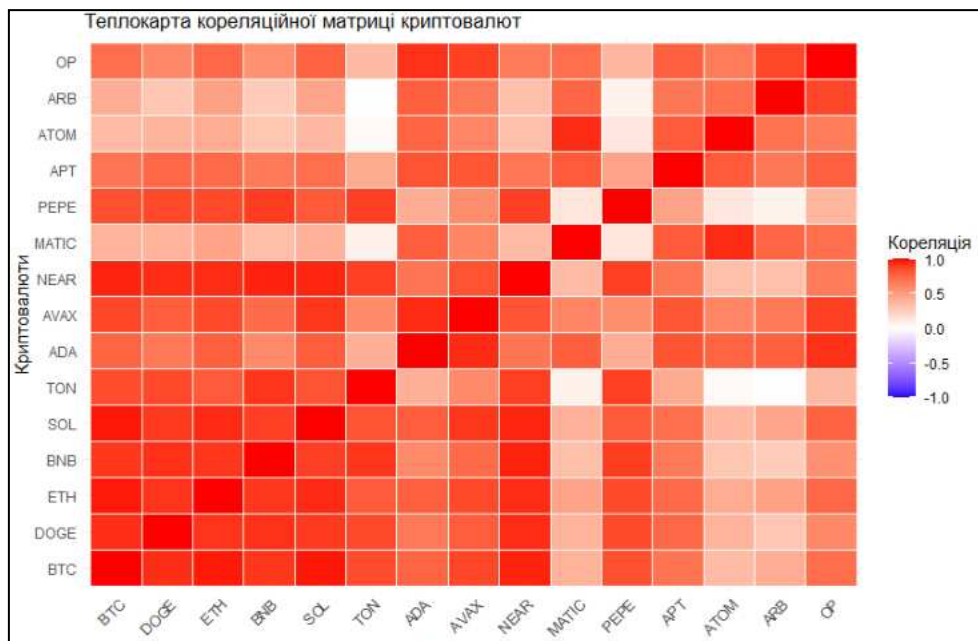


Рисунок 4 – Теплокарта кореляційної матриці криптовалют

Джерело: сформовано автором

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 RStudio для моделювання випадкового розподілу ваги між криптовалютами. Зокрема, ми моделюємо 50 000 портфельів, кожен з яких складається з набору випадково згенерованих співвідношень. Саме щоб продемонструвати можливість методу оптимізації портфеля, ми вибрали велику кількість портфельів. Ми використовуємо модель середньоквадратичного відхилення Марковіца як метод оптимізації портфеля. У кожному конкретному випадку (наприклад, для заданого рівня ризику або очікуваної норми прибутковості) ми будуємо ефективну 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.

Прибутковість і волатильність цих портфельів потім візуалізуються за допомогою діаграми розсіювання, де кожна точка представляє один із 50 000 портфельів (рис. 5).

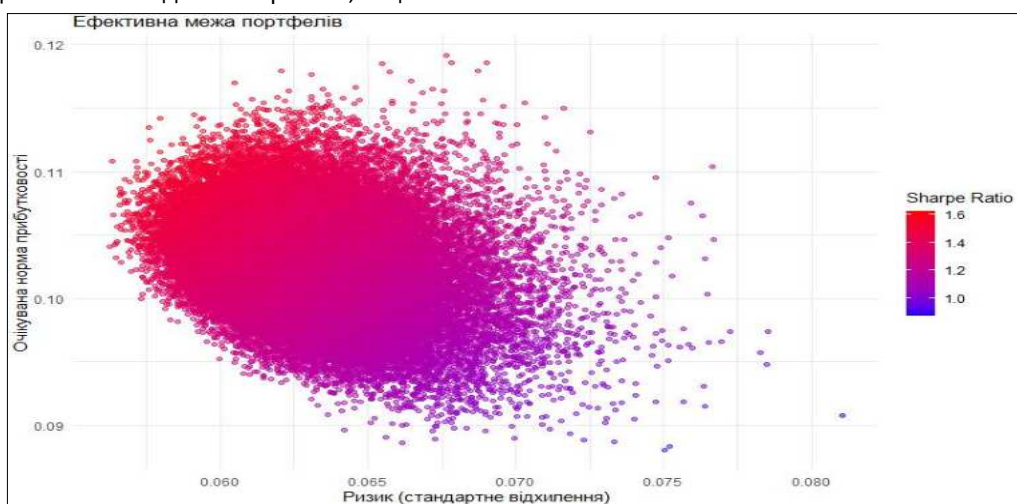


Рисунок 5 – Графік прибутковості обраних криптовалют

Джерело: сформовано автором

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 співвідношення активів.

Таким чином, за отриманими результатами можна зробити певні висновки. Графік на рис. 5 демонструє розподіл портфельів 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 однакової або навіть нижчої норми 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 портфельів. 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 (~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 портфельів, в кінцевому рахунку визначаючи ті, які мають кращу скориговану на ризик ефективність.

На рис. 6 відсотки показують, яку частку кожної з 15 криптовалют займає у найбільш ефективному портфелі.




Рисунок 6 – Структура інвестиційного портфеля криптовалют

Джерело: сформовано автором

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.

2) Ризик (стандартне відхилення): 5.8%. 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.

Даний портфель розрахований на відсутність необхідності постійного контролю за цінами активів. Пасивний депозит можна спокійно контролювати за загальними тенденціями руху крипторинку.

Наступним кроком нами було протестовано ефективність стратегічної моделі інвестиційного портфеля у вигляді імітації довільного входу в ринок на дату останніх цінових даних 16 червня 2024 року. У табл. 1 представлено дані цінових показників та моделі інвестиційного портфеля сформованого на умовний 1 мільйон. За період майже в 7 місяців, більшість криптоактивів дало дуже високий відсоток прибутковості. Просадки в ціні зазнав лише TON. Це можна пояснити певними особливостями та проблемами всієї екосистеми TON, в якій досить багато за останній час вийшло малорезультативних проєктів. Загальний приріст портфеля склав 49.71% – це надзвичайно високий показник для інвестицій такого періоду тривалості. Саме такі результати й роблять крипторинки все більш популярним.

Таблиця 1 Результативність інвестиційного портфеля

Криптовалюти	Ціна 14.06.2024	Частка в портфелі за моделлю Марковіца, %	Вартість активів портфеля за моделлю Марковіца в портфелі	Кількість монет в портфелі	Ціна 07.12.24	Відсоток приросту ціни	Вартість активів портфеля на 15.06.2025 за прогнозом 27.10.2024
BTC	66700.32	13.34	133400	2.00	100346.33	50.44	200691.71
ETH	3465.32	10.46	104600	30.18	4019.13	15.98	121316.77
BNB	599.16	13.64	136400	227.65	755.72	26.13	172042.17
ADA	0.41	0.56	5600	13607.43	1.21	194.02	16464.985
APT	7.69	9.91	99100	12892.42	14.65	90.59	188873.88
ARB	0.91	0.96	9600	10528.39	1.18	29.41	12423.505
ATOM	7.11	8.61	86100	12102.62	10.18	43.09	123204.71
AVAX	30.30	6.95	69500	2293.59	52.36	72.79	120092.14
DOGE	0.14	4.29	42900	304298.48	0.46	227.07	140312.03
MATIC	0.59	11.70	117000	198039.91	0.70	18.87	139083.43
NEAR	5.58	2.73	27300	4893.01	7.76	39.08	37969.742
OP	2.00	5.15	51500	25742.53	2.69	34.46	69247.418
SOL	147.23	5.01	50100	340.27	241.19	63.81	82070.467
PEPE	0.000011	1.19	11900	1053097345.13	0.000026	128.58	27201.504
TON	8.17	5.50	55000	6731.19	6.85	-16.17	46108.639
		Сума:	1000000			Сума:	1497103.1
						Прибуток,%	49.71

Джерело: сформовано автором

Висновки. У цьому дослідженні проведено відбір та 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 Pepe, 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. Водночас деякі криптовалюти, наприклад, TON та ARB, продемонстрували низький рівень кореляції з іншими активами, що вказує на їхню незалежну ринкову динаміку.

Загалом, оптимізація портфельів проводилася за моделлю Марковіца з використанням коефіцієнта Шарпа для вибору найефективніших портфельів. 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.

Також 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 матиме доволі високий рівень, 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.

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.

Література:

1. 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.
2. 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>.
3. 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>.
4. Bitcoin BTC Price. *Coinmarketcap*. URL: <https://www.coingecko.com/en/coins/bitcoin>.
5. 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>.
6. Coingecko. URL: <https://www.coingecko.com/>.
7. 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>.
8. 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>.
9. 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/10.3905/jai.2018.20.3.016>.
10. 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>.
11. 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>.
12. 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).
13. Trimbom 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>.
14. Trimbom S., Li M., Härdle W. K. Investing with Cryptocurrencies - A Liquidity Constrained Investment Approach. *SSRN Electronic Journal*. 2017. URL: <https://doi.org/10.2139/ssrn.2999782>.
15. 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>

References:

1. Oliynyk, V. M., Frolov, S. M., & Leshchenko, Yu. I. (2012). Some aspects of optimization of the portfolio of financial instruments. *Marketing and Innovation Management*, 1(1), 140–147. http://nbuv.gov.ua/UJRN/Mimi_2012_1_17.
2. Aljinović, Z., Marasović, B., & Šestanović, T. (2021). Cryptocurrency Portfolio Selection—A Multicriteria Approach. *Mathematics*, 9(14), 1677. <https://doi.org/10.3390/math9141677>.
3. Bariviera, A. F., Basgall, M. J., Hasperué, W., & Naiouf, M. (2017). Some stylized facts of the Bitcoin market. *Physica A: Statistical Mechanics and Its Applications*, 484, 82–90. <https://doi.org/10.1016/j.physa.2017.04.159>.
4. Belcastro, L., Carbone, D., Cosentino, C., Fabrizio Marozzo, & Trunfio, P. (2023). Enhancing Cryptocurrency Price Forecasting by Integrating Machine Learning with Social Media and Market Data. *Algorithms*, 16(12), 542–542. <https://doi.org/10.3390/a16120542>.
5. Ciaian, P., Rajcaniova, M., & Kancs, d'Artis. (2015). The Economics of BitCoin Price Formation. *Applied Economics*, 48(19), 1799–1815. <https://doi.org/10.1080/00036846.2015.1109038>.
6. CoinGecko. (2024). *Cryptocurrency Prices, Charts, and Crypto Market Cap | CoinGecko*. CoinGecko. <https://www.coingecko.com>.
7. Coinmarketcap. (2024). *Bitcoin*. CoinMarketCap. <https://coinmarketcap.com/currencies/bitcoin/>.
8. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An Introduction to Statistical Learning. In *Springer Texts in Statistics*. Springer New York. <https://doi.org/10.1007/978-1-4614-7138-7>.
9. Kuo Chuen, D. L., Guo, L., & Wang, Y. (2017). Cryptocurrency: A new investment opportunity? *The Journal of Alternative Investments*, 20(3), 16–40. <https://doi.org/10.3905/jai.2018.20.3.016>.
10. Liu, W. (2018). Portfolio diversification across cryptocurrencies. *Finance Research Letters*, 29. <https://doi.org/10.1016/j.frl.2018.07.010>.
11. Rosa, P. D., Felber, P., & Schiavoni, V. (2024). CryptoAnalytics: Cryptocoins price forecasting with machine learning techniques. *SoftwareX*, 26, 101663–101663. <https://doi.org/10.1016/j.softx.2024.101663>.
12. Tay, F. E. H., & Cao, L. (2001). Application of support vector machines in financial time series forecasting. *Omega*, 29(4), 309–317. [https://doi.org/10.1016/s0305-0483\(01\)00026-3](https://doi.org/10.1016/s0305-0483(01)00026-3)
13. Trimborn, S., & Härdle, W. K. (2018). CRIX an Index for cryptocurrencies. *Journal of Empirical Finance*, 49, 107–122. <https://doi.org/10.1016/j.jempfin.2018.08.004>.
14. Trimborn, S., Li, M., & HHrdle, W. K. (2017). Investing with Cryptocurrencies - A Liquidity Constrained Investment Approach. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2999782>.
15. Yi, Y. (2024). Research on cryptocurrency portfolio based on Markowitz model. *Highlights in Business Economics and Management*, 32, 237–254. <https://doi.org/10.54097/6q50bk41>.



Ця робота ліцензована Creative Commons Attribution 4.0 International License