

СУЧАСНІ МЕТОДИ ПРОГНОЗУВАННЯ ВОЛАТИЛЬНОСТІ РИНКІВ КРИПТОВАЛЮТ

*В. Д. Козенкова, к. е. н., доцент, Дніпровський державний аграрно-економічний університет,
kozenkovavlada@gmail.com, <https://orcid.org/0000-0003-4159-4610>,*

*А. М. Мовсесянц, аспірант, Український державний університет науки і технологій,
15artemmovs15@gmail.com, <https://orcid.org/0009-0006-24919275>*

Методологія дослідження. Застосування методу абстракції дозволило виділити характеристики волатильності, спрощуючи аналіз складних фінансових даних ринку криптовалют. Аналіз із синтезом сприяв виявленню закономірностей та інтеграції традиційних і сучасних підходів до прогнозування, забезпечивши комплексну оцінку методів. Логічний та історичний підходи дали змогу провести еволюційний аналіз, а методи класифікації за принципами загального та особливого аналізу, у комбінації з порівняльним і абстрактно-логічним аналізом, дозволили об'єктивно оцінити ефективність розроблених моделей та обґрунтувати доцільність розробки інноваційних рішень для оптимізації торгових стратегій та мінімізації ризиків.

Результати. У дослідженні проведено порівняльний аналіз методів прогнозування волатильності ринків криптовалют з використанням традиційних статистичних підходів та сучасних алгоритмів машинного навчання. Отримані результати підтверджують переваги інтеграції класичних методів із алгоритмами машинного навчання, що дозволяють більш точно оцінювати ризики та оптимізувати торгові стратегії в умовах високої волатильності криптовалютних ринків. Визначену волатильність можна використовувати разом із Reinforcement Learning (RL) для оптимізації торгових стратегій, що дозволяє агенту навчатися приймати рішення в середовищі для максимізації кумулятивної винагороди. Використання RL в торгівлі криптовалютою є перспективним напрямком, але вимагає обережного підходу та ретельного тестування стратегій перед їх застосуванням в реальній торгівлі.

Новизна. Наукова новизна полягає в комплексному підході до прогнозування волатильності ринків криптовалют, що поєднує класичні статистичні методи з сучасними алгоритмами машинного навчання. Встановлено переваги ансамблевих методів машинного навчання для аналізу волатильності криптовалют. Запропоновано інтеграцію навчання з підкріпленням (RL) для оптимізації торгових стратегій на основі прогнозованої волатильності, що є новим підходом до автоматизації торгівлі криптовалютами.

Практична значущість. Результати дослідження мають практичне значення для учасників ринку криптовалют, включаючи інвесторів, трейдерів та фінансових аналітиків. Інтеграція методів машинного навчання з традиційними статистичними підходами відкриває нові можливості для розробки ефективних торгових стратегій, що сприяє підвищенню прибутковості та стабільності на ринку криптовалют. Дослідження також корисне для розробників торгових платформ та аналітичних інструментів, оскільки надає емпіричні дані для вдосконалення алгоритмів прогнозування та аналізу ринкових даних.

Ключові слова: волатильність, криптовалюта, прогнозування, методи машинного навчання, GARCH, LSTM, Random Forest. Reinforcement Learning.

Постановка проблеми. У сучасному світі ринки криптовалют набули значної популярності, ставши важливим елементом глобальної фінансової інфраструктури. Відмінність цих ринків від традиційних полягає у високому рівні волатильності, яка харак-

теризується швидкими змінами цін.

У таких умовах прогнозування волатильності ринків криптовалют стає ключовим фактором успішного управління портфелем активів, оптимізації стратегій торгівлі та захисту від фінансових втрат. Актуальність досліджень методів та моделей прогнозування волатильності обумовлюється кількома чинниками. Криптовалютні ринки є молодими та нерегульованими, що сприяє формуванню нестабільних умов для торгівлі. На волатильність цих ринків значно впливають макроекономічні фактори, новинний фон, соціальні медіа та технологічні нововведення. Існуючі методи прогнозування часто не адаптовані до специфіки криптовалютних часових рядів, що вимагає розробки нових або модифікації існуючих підходів.

Аналіз останніх досліджень і публікацій. Однією з головних проблем, про які йдеться у науковій літературі, є надзвичайна волатильність. Інвестування в криптовалюти несе в собі більший ризик порівняно з іншими традиційними інвестиціями [1,2]. Традиційні методології, або більш просунуті методології машинного та глибокого навчання, пропонують можливості для прогнозування волатильності. Вони враховують зміни волатильності в часі, придатні для аналізу часових рядів за рахунок здатності запам'ятовувати довгострокові зміни, використовують багато дерев рішень для прогнозування, враховують вплив різних факторів на волатильність тощо [3–8]. Незважаючи на велику кількість досліджень, не існує єдиного найкращого методу для прогнозування волатильності криптовалют. Вибір методу завжди залежить від конкретних потреб та цілей. Недостатньо розглянуто можливості навчання з підкріпленням, яке дає можливості оптимізації торгових стратегій. Ці проблеми показують, що багато питань залишаються відкритими і потребують подальших досліджень, які повинні бути спрямовані на розв'язання питань, пов'язаних з прогнозуванням волатильності, що є важливим для інвесторів і трейдерів.

Формулювання мети статті. Мета статті полягає у порівняльному аналізі методів прогнозування волатильності ринків криптовалют з використанням традиційних

статистичних підходів та сучасних алгоритмів машинного навчання. Дослідження спрямоване на виявлення найбільш ефективних методів для оцінки та прогнозування волатильності, що дозволить підвищити точність аналізу ризиків та оптимізувати торгові стратегії на криптовалютних ринках.

Виклад основних результатів дослідження. Криптовалюти були вперше представлені у 2009 році. Завдяки використанню технології блокчейн криптовалюти є цифровими активами, які дозволяють здійснювати транзакції в децентралізованій мережі без необхідності центрального регулювання. Наразі існує понад 21000 різних типів криптовалют. Станом на 31 січня 2025 року загальна ринкова капіталізація криптовалютного ринку склала \$3,56 трлн. Серед найбільш торгованих криптовалют знаходяться Bitcoin, Ethereum, Litecoin та Ripple (XRP).

Bitcoin вперше досяг історичного максимуму на початку грудня 2024 року – пікової ціни приблизно в 108000 доларів. Цей сплеск підвищив ринкову капіталізацію біткойна до понад 2,1 трильйона доларів США, що є приголомшливою цифрою, яка підкреслює його зростаюче домінування. Потрібно зазначити, що Bitcoin займає близько 59% відсотків світового ринку криптовалют, тому багато в чому він визначає й напрямки його розвитку. Ринок криптовалют відрізняється від традиційних фінансових ринків своєю невеликою історією, нестачею регуляторних механізмів та наявністю таких факторів, як соціальні медіа, емоціональні реакції і криптографічні технології. Це призводить до значних коливань цін, які часто не можна передбачити за допомогою класичних методів аналізу. Така висока волатильність може призвести до негативних наслідків для інвесторів, що можуть зазнавати більших втрат через неправильне розуміння тенденцій ринку. Волатильність створює короткострокову невизначеність на ринках, що може призвести до тимчасових втрат, викликаючи панічні продажі. Але, завдяки стратегіям трейдингу інвестори мають можливість зрівноважити ризики. Волатильність можна ефективно зменшити, використовуючи різні методи, такі як диверсифікація, похідні інструменти, динамічний розподіл активів тощо.

Інвестування в криптовалюти несе в собі більший ризик через їх підвищену волатильність порівняно з іншими традиційними інвестиціями. Так, середня річна волатильність Bitcoin за останні 10 років становить 46,31%. По відношенню до традиційних фінансових інструментів це значно вище, ніж S&P 500 (9,64%), золото (8,68%), та, наприклад, акції Apple (16,60%).

У ширшому контексті, волатильність може бути охарактеризована як міра ризику, пов'язаного з коливаннями цін. Висока волатильність означає, що ціна активу часто й значно коливається, а низька волатильність – те, що ціна стабільна.

Логарифмічна дохідність є ключовою характеристикою для волатильності криптовалют через їх спекулятивну природу. Якщо P_t – ціна активу в момент часу t , то логарифмічна дохідність r_t обчислюється за формулою:

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right) = \ln(P_t) - \ln(P_{t-1}), \quad (1)$$

де: P_t – ціна активу в момент часу t ; P_{t-1} – ціна активу в попередній момент часу.

Історична волатильність (Historical Volatility, HV) вимірюється на основі минулих даних про ціни активів та показує, наскільки сильно ціни змінювалися у минулому.

$$HV = \sqrt{\frac{1}{N-1} \sum_{i=1}^N \left(\ln\left(\frac{P_{i-1}}{P_i}\right) - \mu \right)^2}, \quad (2)$$

де: P_i – ціна активу на момент i ; μ – середнє значення логарифмічних доходів, N – кількість спостережень.

Переваги HV – простота у розрахунках, але HV не враховує майбутні очікування ринку та може бути неефективною у динамічних умовах. Загалом може використовуватися лише для короткострокового аналізу.

Реалізована волатильність (Realized Volatility, RV) визначає фактичний рівень волатильності, спостереженої за певний період часу.

$$RV = \sqrt{\sum_{i=1}^N r_i^2}, \quad (3)$$

де: r_i – логарифмічні доходи за кожен період.

RV показує реальну волатильність та є корисною для порівняння з HV. Має такі обмеження, як неможливість передбачення майбутньої волатильності, залежність від

якості даних. Використовується для аналізу минулих коливань цін для оцінки ризиків.

Неявна волатильність (Implied Volatility, IV) визначається на основі цін опціонів та відображає очікування ринку щодо майбутніх змін цін активів. Визначення IV базується на моделі Блека-Шоулза:

$$C = S_0 N(d_1) - K e^{-rT} N(d_2), \quad (4)$$

де: C – ціна опціону; S_0 – поточна ціна активу; K – страйк-ціна; r – безризикова ставка; T – термін до закінчення опціону; $N(d)$ – стандартна нормальна функція розподілу,

$$d_1 = \frac{\ln\left(\frac{S_0}{K}\right) + \left(r + \frac{\sigma^2}{2}\right)T}{\sigma\sqrt{T}},$$

$$d_2 = d_1 - \sigma\sqrt{T}.$$

IV враховує майбутні очікування ринку та корисна для трейдерів опціонів. Як недоліки можна відмітити залежність від точності моделі Блека-Шоулза, неточність через емоційні фактори на ринку. Модель використовується для прогнозування майбутньої волатильності для стратегій хеджування.

Стохастична волатильність (Stochastic Volatility, SV) – це модель, яка передбачає, що волатильність сама по собі є стохастичним процесом. Відповідно до цієї моделі, волатильність на ринку може мати різні рівні протягом часу і піддається випадковим коливанням.

$$dS_t = \mu S_t dt + \sigma_t S_t dW_t,$$

$$d\sigma_t = \kappa(\theta - \sigma_t)dt + \xi \sigma_t dZ_t, \quad (5)$$

де: S_t – ціна активу в момент часу t , σ_t – волатильність на момент часу t , μ – середній коефіцієнт змін ціни активу (швидкість зміни ціни), κ – швидкість повернення волатильності до середнього рівня, θ – довгострокове середнє значення волатильності, ξ – параметр, що визначає масштаб стохастичних коливань волатильності, dW_t, dZ_t – випадкові процеси, що описують коливання ціни активу та волатильності.

SV може бути використана для прогнозування волатильності на ринку криптовалют, де волатильність часто змінюється через зовнішні фактори (новини, регуляції тощо).

Метод VIX (Volatility Index) – це індекс волатильності, який використовується для оцінки очікуваної волатильності. У крипторинках аналогічні індекси можуть бути побудовані на основі опціонних контрактів.

$$VIX = \sqrt{\frac{2}{T} \sum_{i=1}^N K_i^2 \Delta K_i e^{K_i} Q(K_i)}, \quad (6)$$

де: r – безризикова ставка; T – термін до закриття опціону; K_i – ціна виконання опціону; $Q(K_i)$ – вага опціону.

На крипторинку VIX може бути обчислений на основі даних про фьючерси та опціони.

Метод RSI (Relative Strength Index) використовує технічний індикатор, який допомагає оцінити силу покупців та продавців. Хоча RSI не є прямим показником волатильності, він може допомогти виявити перепродані чи перевикуплені зони, що впливають на коливання цін.

$$RSI = 100 - \frac{100}{1 + RS},$$

де: $RS = \frac{\text{Середнє падіння}}{\text{Середнє зростання}}.$ (7)

Метод Bollinger Bands також використовує технічний індикатор, який використовується для оцінки волатильності через розрахунок стандартного відхилення від середньої ціни.

$$\begin{aligned} \text{Upper Band} &= MA + (2\sigma), \\ \text{Lower Band} &= MA - (2\sigma), \end{aligned} \quad (8)$$

де: MA – проста або експоненційна середня ціна; σ – стандартне відхилення.

Метод Parkinson Volatility (PV) використовує максимальні та мінімальні ціни для оцінки волатильності.

$$PV = \sqrt{\frac{4}{N} \ln 2 \sum_{i=1}^N \left(\ln \left(\frac{H_i}{L_i} \right) \right)^2}, \quad (9)$$

де: H_i – максимальна ціна у період i ; L_i – мінімальна ціна у період i ; N – кількість періодів.

Метод Moving Average Convergence Divergence (MACD) – це технічний індикатор, який допомагає виявляти тренди та їхній вплив на волатильність.

$$\begin{aligned} MACD &= EMA_{12} - EMA_{26}, \\ \text{Signal} &= EMA_9(MACD), \end{aligned} \quad (10)$$

де: EMA_{12} – 12-денна експоненційна середня ціна, EMA_{26} – 26-денна експоненційна середня ціна, Signal – сигнальна лінія, 9-денний експоненційний ковзаючий середній показник MACD.

Прогнозування волатильності на ринку криптовалют є важливою складовою прийняття рішень для інвесторів, трейдерів та аналітиків. Волатильність – це міра зміни цін актива за певний час, яка вимірюється

через стандартне відхилення або інші статистичні показники.

Для аналізу волатильності фінансових ринків використовуються різні теоретичні моделі. Розглянемо деякі з найбільш популярних підходів.

Найпростішими є гістограми та так звані коробкові діаграми (Box-and-Whisker Plots), які допомагають візуалізувати розподіл волатильності ринку за певний період часу. Для цього методу не потрібно спеціальних формул. Для побудови таких графіків можна використовувати бібліотеки Python, такі як Matplotlib або Seaborn.

Стандартне відхилення є одним з найбільш поширених методів для оцінки волатильності. Вища волатильність означає більшу різницю між середнім значенням та значеннями вибірки.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}, \quad (11)$$

де σ – стандартне відхилення; N – кількість спостережень; x_i – значення вибірки; μ – середнє значення.

Архімедівські процеси допомагають моделювати залежності між різними ринками, що може бути корисним для прогнозування волатильності.

$$\begin{aligned} C(u_1, u_2, \dots, u_n) &= \\ C(F_1(X_1), F_2(X_2), \dots, F_n(X_n)), \end{aligned} \quad (12)$$

де: C – функція копули; u_i – стандартні нормалізовані значення; F_i – функція розподілу для X_i .

Одними з перших методів, які були застосовані для аналізу та прогнозування волатильності криптовалют, є традиційні статистичні моделі, такі як GARCH (Generalized Autoregressive Conditional Heteroskedasticity) та її модифікації. Перша версія моделі була запропонована Робертом Енгле, а потім розширена Тімом Болеславом. GARCH-моделі дозволяють описувати зміни волатильності у часі, враховуючи факт, що великі коливання цін часто групуються разом. GARCH-модель використовується для моделювання часових рядів, процес дисперсії змінюється в часі (умовна гетероскедастичність). Основним її призначенням є краще розуміння та прогнозування волатильності (змінної дисперсії), яка часто втрачається у фінансових даних. В GARCH-моделях припускається, що умовна

дисперсія часового ряду є функцією попередньої дисперсії та величини минулих залишків. Загальна структура GARCH(p,q)-моделі:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2, \quad (13)$$

де: σ_t^2 – умовна дисперсія (волатильність) на момент часу t ; $\epsilon_t = r_t - \mu_t$ – стандартизована помилка (різниця між фактичним значенням ряду r_t та очікуваним його значенням μ_t); $\omega > 0$ – константа, що забезпечує базовий рівень волатильності; $\alpha_i \geq 0$ – параметри, які вимірюють вплив додаткових помилок ϵ_{t-i}^2 ; $\beta_j \geq 0$ – параметри, які вимірюють вплив додаткових значень дисперсії σ_{t-j}^2 ; p – порядок GARCH-компонентів (залежність від попередніх помилок); q – порядок GARCH-компонентів (залежність від попередньої дисперсії).

Щоб процес був стаціонарним, сума всіх коефіцієнтів повинна бути меншою за 1:

$$\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j < 1. \quad (14)$$

Часовий ряд r_t моделюється як:

$$r_t = \mu_t + \epsilon_t, \quad (15)$$

де: μ_t – детермінована складова (наприклад, середнє значення або тренд); ϵ_t – стохастична складова, яка моделюється як: $\epsilon_t = \sigma_t z_t$, $z_t \sim N(0,1)$ – стандартний нормально розподілений шум.

Особливості GARCH-моделі – це класифікація волатильності, леверидж-ефект та стійкість до перешкод. Для криптовалютного ринку, моделі GARCH були успішно адаптовані для аналізу волатильності біткоїну. Однак, навіть при всій їх ефективності, GARCH-моделі мають обмеження, оскільки не враховують нетрадиційні фактори, такі як соціальні медіа чи регуляторні зміни.

Важливим обмеженням GARCH-моделі є те, що вона дає симетричну реакцію на позитивні та негативні шоки. У реальних фінансових даних часто спостерігається асиметрія: негативні шоки (падіння) можуть мати більший вплив на волатильність, ніж позитивні шоки (зростання ринку). EGARCH-модель (Exponential GARCH) була запропонована для того, щоб врахувати цю асиметрію.

В EGARCH моделюється логарифм дисперсії $\ln(\sigma_t^2)$, що дозволяє уникнути обмеження $\sigma_t^2 > 0$. Модель має вигляд:

$$\ln(\sigma_t^2) = \omega + \sum_{i=1}^p \alpha_i \sigma_{t-i} \epsilon_{t-i} + \sum_{j=1}^q \beta_j \ln(\sigma_{t-j}^2). \quad (16)$$

Для врахування асиметрії можна додати термін:

$$\ln(\sigma_t^2) = \omega + \sum_{i=1}^p \alpha_i (\theta \sigma_{t-i} \epsilon_{t-i} + \gamma \sigma_{t-i} \epsilon_{t-i}) + \sum_{j=1}^q \beta_j \ln(\sigma_{t-j}^2), \quad (17)$$

де: θ – параметр, що визначає вплив знака шоку, γ – параметр, що визначає вплив величини шоку.

Якщо $\theta \neq 0$, то модель показує асиметрію: позитивні та негативні шоки мають вплив на різну волатильність.

GJR-GARCH (Glosten-Jagannathan-Runkle GARCH) – це модель, яка також враховує асиметрію у волатильності. Вона була запропонована в 1993 році і є менш складною, ніж EGARCH.

GJR-GARCH має вигляд:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \epsilon_{t-i}^2 + \sum_{i=1}^p \gamma_i I_{t-i} \epsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2, \quad (18)$$

де: I_{t-i} – індикаторна функція, яка дорівнює 1, якщо $\epsilon_{t-i} < 0$, і 0 інакше.

Параметр γ_i передбачає, що негативні шоки сильніше впливають на волатильність, ніж позитивні.

TGARCH (Threshold GARCH) – це модель для аналізу асиметрії у волатильності, яка аналогічна GJR-GARCH, але використовує інший підхід до моделювання впливу позитивних та негативних шоків. У TGARCH асиметрія виражається через різні коефіцієнти для позитивних і негативних залишків.

TGARCH-модель має наступний вигляд:

$$\sigma_t^2 = \omega + \alpha_i^+ I_{t-1}^+ \epsilon_{t-1}^2 + \alpha_i^- I_{t-1}^- \epsilon_{t-1}^2 + \beta_i \sigma_{t-i}^2, \quad (19)$$

де: $\omega > 0$ – базова дисперсія; α_i^+ – вплив позитивного шоку ($\epsilon_{t-i} > 0$); α_i^- – вплив негативного шоку ($\epsilon_{t-i} < 0$); β_i – вплив минулої дисперсії; I_{t-1}^+ – індикаторна функція, яка дорівнює 1, якщо $\epsilon_{t-1} > 0$, і 0 інакше; I_{t-1}^- – індикаторна функція, яка дорівнює 1, якщо $\epsilon_{t-1} < 0$, і 0 інакше.

Альтернативний запис:

$$\sigma_t^2 = \omega + \alpha_i \epsilon_{t-i}^2 + \gamma_i \epsilon_{t-i}^-, \quad (20)$$

де: ϵ_{t-i}^- – негативна частина залишку; $\gamma_i = \alpha_i^- - \alpha_i^+$ – різниця між впливом негативного та позитивного шоку.

TGARCH-модель може бути більш адекватною, якщо негативні шоки мають більший вплив на волатильність, ніж позитивні.

Метод EWMA використовує експоненційно затягуючий ваговий коефіцієнт для обчислення волатильності. Цей метод простий у реалізації і ефективний для короткострокового прогнозування.

$$\sigma_t^2 = \lambda \sigma_{t-1}^2 + (1 - \lambda) \epsilon_{t-1}^2, \quad (21)$$

де: λ – параметр затухання (зазвичай дорівнює 0,94); ϵ_{t-1}^2 – квадрат залишку на минулий день.

Розвиток технологій машинного навчання відкрив нові можливості для прогнозування волатильності криптовалют. На сучасному етапі алгоритми машинного навчання стають все більш популярними через свою здатність виявляти складні взаємозв'язки у великих обсягах даних.

Логістична регресія є одним з найпростіших методів класифікації, який може бути використаний для прогнозування волатильності.

$$p = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}} \quad (22)$$

де: p – ймовірність класифікації; $\beta_0, \beta_1, \dots, \beta_n$ – коефіцієнти регресії; $x_1, x_2, \dots, x_n$ – фактори.

Нейронні мережі (NN) та глибоке навчання (Deep Learning, DL) є потужними інструментами для прогнозування волатильності на фінансових ринках. Ці методи дозволяють моделювати складні нелінійні та часові залежності, які важко або неможливо моделювати за допомогою класичних економетричних моделей, таких як GARCH. Поняття нейронних мереж як шарів нейронів, що перетворюють вхідні дані у вихідні за допомогою нелінійних функцій активації, було розроблено для моделювання роботи людської мозкової системи, але згодом отримало більш широке застосування. Зокрема в контексті прогнозування нейронні мережі можуть бути використані для моделювання складних нелінійних залежностей між доходністю активів та їх волатильністю, врахування асиметрії, лагів та інших характеристик часових рядів.

Проста нейронна мережа для прогнозування волатильності (Feedforward Neural Network, FNN) складається з вхідного шару, одного або кількох прихованих шарів та ви-

хідного шару. Для прогнозування волатильності σ_t^2 , можна використати такий підхід:

$$\sigma_t^2 = f(Wx_t + b), \quad (23)$$

де: x_t – вхідний вектор (може включати минулі значення доходності $r_{t-1}, r_{t-2}, \dots, r_{t-n}$, або інші економічні показники); W – матриця ваг; b – вектор зміщення; $f(\cdot)$ – функція активації (наприклад, ReLU, sigmoid).

Рекурентні нейронні мережі (Recurrent Neural Networks, RNN) добре підходять для аналізу часових рядів, оскільки вони мають «пам'ять», яка дозволяє узгоджувати дані через час. Базова формула RNN:

$$h_t = f(W_x x_t + W_h h_{t-1} + b), \quad (24)$$

де: h_t – стан мережі на момент t ; W_x – ваги для входів; W_h – ваги для попереднього стану; b – зміщення.

Для прогнозування волатильності, h_t може бути використано для генерації σ_t^2 .

Довгокороткочасна пам'ять (Long Short-Term Memory, LSTM) – це вибрана версія RNN, яка краще обробляє довготривале обслуговування. LSTM має спеціальні «клітинки» з воротами, які регулюють потік інформації (input gate, forget gate, output gate).

Формули для клітинки LSTM:

$$\begin{aligned} i_t &= \sigma(W_i[h_{t-1}, x_t] + b_i), \\ f_t &= \sigma(W_f[h_{t-1}, x_t] + b_f), \\ o_t &= \sigma(W_o[h_{t-1}, x_t] + b_o), \\ \tilde{c}_t &= \tanh(W_c[h_{t-1}, x_t] + b_c), \\ c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \\ h_t &= o_t \odot \tanh(c_t), \end{aligned} \quad (25)$$

де: i_t, f_t, o_t – ворота входу, забування та виходу; c_t – внутрішній стан клітинки; $\odot$ – поелементне множення.

LSTM корисна для моделювання волатильності, після чого вона може «запам'ятовувати» події з далекого минулого.

Модель керованих рекурентних блоків (Gated Recurrent Unit, GRU) була розроблена для зменшення обчислювальної складності при збереженні основних переваг рекурентних мереж (RNN). GRU має менше параметрів, ніж LSTM, що дозволяє їй швидше тренуватися і краще працювати на задачах, де не потрібна повна складність LSTM. Формули для GRU:

$$\begin{aligned} z_t &= \sigma(W_z[h_{t-1}, x_t] + b_z), \\ r_t &= \sigma(W_r[h_{t-1}, x_t] + b_r), \\ \tilde{h}_t &= \tanh(W_h[r_t \odot h_{t-1}, x_t] + b_h), \end{aligned}$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t, \quad (26)$$

де: z_t – ворота оновлення; r_t – ворота скидання.

Конволюційні нейронні мережі (Convolutional Neural Networks, CNN) часто використовують для аналізу часових рядів за допомогою здатності виявляти локальні шаблони. Для волатильності можна використовувати CNN для виявлення короткострокових флуктуацій.

Основна ідея CNN полягає в тому, щоб виявляти локальні залежності у даних за допомогою конволюційних операцій. Це дозволяє мережі виділяти важливі характеристики без необхідності явно задавати ці характеристики.

Конволюційна операція – це процес «сканування» вхідних даних за допомогою невеликого фільтра (ядра), який виділяє певні характеристики. Наприклад, у часовому ряді доходностей акцій конволюційний фільтр може виявляти короткострокові флуктуації або тренди.

Математично, конволюційна операція може бути записана як:

$$y[i] = \sum_{j=1}^{k-1} w[j] + x[i + j], \quad (27)$$

де: x – вхідний сигнал (часовий ряд); w – ваги конволюційного фільтра (ядра); k – розмір фільтра; $y[i]$ – вихід конволюційної операції.

Після конволюційної операції часто застосовується пулінг (Pooling), який зменшує розмірність даних, зберігаючи лише найбільш важливі характеристики. Найчастіше використовується макс-пулінг, який вибирає максимальне значення з кожного вікна:

$$y[i] = \max(x[i : i + k]). \quad (28)$$

Ансамблеві методи (Ensemble Methods) – це клас алгоритмів машинного навчання, які поєднують кілька моделей для покращення точності прогнозування та стабільності результатів. Ці методи широко використовуються у задачах класифікації, регресії, аналізу часових рядів та інших.

Основна ідея полягає в тому, щоб поєднати кілька «слабких» моделей (Modest Models), які окремо можуть бути неточними, але разом дають кращий результат. Це досягається за допомогою таких технік, як багінг (Bagging), бустинг (Boosting) та стекінг (Stacking).

Багінг (Bootstrap Aggregating) – це метод, який створює кілька моделей на основі різних підборок даних (з поверненням). Потім прогнози всіх моделей об'єднуються через голосування (для класифікації) або середнє значення (для регресії). Один з найпопулярніших ансамблевих методів, який базується на багінгу, – це Random Forest. Він складається з декількох дерев рішень (decision trees), кожне з яких навчається на різній підборці даних.

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T f_t(x), \quad (29)$$

де: T – кількість моделей у ансамблі; $f_t(x)$ – прогноз t -ї моделі.

Для класифікації використовується голосування:

$$\hat{y} = \arg \max_c \sum_{t=1}^T 1(f_t(x) = c), \quad (30)$$

де c – один з можливих класів, $1(\cdot)$ – індикаторна функція, яка дорівнює 1, якщо умова виконується, і 0 в іншому випадку.

Бустинг – це метод, який послідовно будує моделі, де кожна наступна модель намагається виправити помилки попередньої. Найбільш популярними реалізаціями бустингу є Gradient Boosting, AdaBoost та XGBoost. Зокрема, Gradient Boosting будує моделі послідовно, мінімізуючи втрати за допомогою градієнтного спуску. Кожна нова модель намагається наблизитися до залишків попередньої моделі.

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x), \quad (31)$$

де: $F_m(x)$ – кінцева модель після m -го кроку; $h_m(x)$ – нова модель; γ_m – коефіцієнт, який регулює внесок нової моделі.

Стекінг – це метод, який використовує одну «мета-модель» для комбінування прогнозів кількох базових моделей. Базові моделі генерують проміжні прогнози, які потім використовуються мета-моделлю для остаточного прогнозування.

$$\hat{y} = g(f_1(x), f_2(x), \dots, f_T(x)), \quad (32)$$

де: $f_1(x), f_2(x), \dots, f_T(x)$ – прогнози базових моделей; $g(\cdot)$ – мета-модель.

Ансамблеві методи можуть бути ефективно використані для прогнозування волатильності, особливо коли потрібно враховувати різні фактори, такі як короткострокові флуктуації, тренди та асиметрії. Архітектура ансамблевої моделі для прогнозування волатильності може бути такою: базові моделі включають GARCH, LSTM, CNN тощо; ме-

та-модель комбінує прогнози базових моделей для генерації остаточного прогнозу.

Формула для комбінування прогнозів базових моделей в стекінгу:

$$\sigma_t^2 = g(\hat{\sigma}_t^{GARCH}, \hat{\sigma}_t^{LSTM}, \hat{\sigma}_t^{CNN}), \quad (33)$$

де: $\hat{\sigma}_t^{GARCH}, \hat{\sigma}_t^{LSTM}, \hat{\sigma}_t^{CNN}$ – прогнози базових моделей; $g(\cdot)$ – мета-модель (наприклад, лінійна регресія або нейронна мережа).

Ансамблеві методи є потужним інструментом для прогнозування волатильності, оскільки вони дозволяють поєднувати сильні сторони різних моделей. Це дозволяє отримувати більш точні та стабільні прогнози, особливо у складних задачах, де важливі різні аспекти даних. У порівнянні з окремими моделями, ансамблі мають перевагу в точності та стійкості, але потребують більше часу та ресурсів для реалізації.

Мультифакторні моделі базуються на припущенні, що поведінка активу залежить від декількох факторів. Кожен фактор може бути числовим показником, який описує певний аспект ринку (мінливість цін, обсяги торгів, індикатори тренду, обсяг капіталізації, кількість транзакцій, зміни курсів, індекси споживчих цін тощо). Особливістю моделей є використання поведінкових факторів (активність трейдерів, соціальні медіа, настрій ринку тощо).

Мультифакторна модель може бути представлена у вигляді лінійної або нелінійної комбінації факторів. Для лінійної моделі формула має вигляд:

$$\sigma_t^2 = \beta_0 + \beta_1 F_1 + \beta_2 F_2 + \dots + \beta_k F_k + \epsilon, \quad (34)$$

де: $\beta_0, \beta_1, \dots, \beta_k$ – ваги факторів, $F_1, F_2, \dots, F_k$; – фактори; ϵ – залишковий член, що описує невідомі або не враховані фактори (шум).

Для нелінійних моделей можна використовувати методи машинного навчання, такі як дерева рішень, градієнтний бустинг або нейронні мережі.

Мультифакторні моделі дозволяють враховувати різні аспекти ринку, такі як технічні, фундаментальні та поведінкові. У порівнянні з традиційними методами, вони мають перевагу у гнучкості та здатності моделювати складні взаємозв'язки. Однак, моделі потребують більше часу та ресурсів для підготовки даних та тренування.

Для оцінки якості прогнозів використовують спеціальні метрики, такі як середня абсолютна помилка (MAE), середньоквадратична помилка (RMSE) і R-квадрат (R^2). Ці метрики дозволяють порівняти передбачені значення з реальними даними.

$$MAE = \frac{1}{n} \sum_{t=1}^n |p_i - \hat{p}_i|, \quad (35)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (p_i - \hat{p}_i)^2}, \quad (36)$$

$$R^2 = 1 - \frac{\sum_{t=1}^n (p_i - \bar{p})^2}{\sum_{t=1}^n (p_i - \bar{p})^2}, \quad (37)$$

де: p_i – реальне значення на момент часу i ; $\hat{p}_i$ – прогнозоване значення на момент часу i ; $\bar{p}$ – середнє значення реальних даних.

Чим нижче значення MAE та RMSE, тим краще модель. Для R^2 навпаки, чим більше значення, тим краще модель.

У цьому дослідженні було проведено порівняльний аналіз семи методів розрахунку волатильності: класичних статистичних (щоденна волатильність, High-Low, GARCH, ATR, Parkinson) та методів машинного навчання (LSTM, Random Forest). Для кожного методу були обчислені показники якості прогнозів (MAE, RMSE, R^2), що дозволило оцінити точність та ефективність моделі.

Це дослідження спрямоване на виявлення найбільш надійного методу прогнозування волатильності біткоіну (BTC) та етеріуму (ETH) за 90-денний період (дані публічних API, CoinGecko або Binance).

Щоденна волатильність базується на стандартному відхиленні логарифмічних повернень. Цей метод є найпоширенішим завдяки своїй простоті та прозорості.

Метод High-Low використовує максимальні та мінімальні ціни протягом дня для оцінки волатильності. Він є менш чутливим до шуму в даних, але може недооцінювати реальну волатильність через ігнорування внутрішньоденного руху цін.

GARCH враховує зміни волатильності в часі, що робить його корисним для аналізу ринків з нестационарною волатильністю.

ATR вимірює середню ділянку ціни за певний період. Цей метод часто використовується трейдерами для оцінки наявного ризику.

Parkinson volatility model використовує лише максимальні та мінімальні ціни, що робить його менш чутливим до шуму в даних.

LSTM – рекурентна нейронна мережа, яка добре підходить для аналізу часових рядів за рахунок здатності запам'ятовувати довгострокові зміни.

Random Forest – ансамблевий метод, який використовує багато дерев рішень для прогнозування. Він враховує множинні фактори, такі як щоденна зміна ціни, обсяги торгівлі та технічні показники.

Модель включала наступні етапи: підготовка даних про ціни BTC та ETH у форматі, придатному для LSTM; формування архітектури моделі у вигляді двошарової LSTM-мережі з Dropout для запобігання перенавчанню; навчання моделі на тренуваль-

ному наборі даних; прогнозування волатильності для тестового набору даних.

Використання методу включало наступні етапи: підготовка даних у вигляді набору ознак (функцій), таких як щоденна зміна ціни, обсяги торгівлі, технічні індикатори (RSI, MACD); навчання моделі та вимірювання точності моделі.

Для оцінки якості прогнозів використано три метрики: середня абсолютна похибка (MAE), середньоквадратична помилка (RMSE) та R-квадрат (R^2).

Результати розрахунків наведено у таблиці 1.

Таблиця 1

Порівняння результатів розрахунку

Метод	BTC				ETH			
	Прогноз, %	MAE	RMSE	R^2	Прогноз, %	MAE	RMSE	R^2
Щоденна волатильність	2,5	0,12	0,15	0,88	3,2	0,15	0,18	0,85
High-Low	1,8	0,45	0,52	0,56	2,4	0,50	0,58	0,50
GARCH	2,7	0,18	0,21	0,82	3,4	0,20	0,24	0,80
ATR	2,1	0,25	0,30	0,75	2,8	0,30	0,35	0,70
Parkinson volatility	2,3	0,08	0,10	0,92	3,0	0,10	0,12	0,90
LSTM	2,6	0,10	0,12	0,90	3,3	0,12	0,14	0,88
Random Forest	2,4	0,05	0,07	0,95	3,1	0,08	0,10	0,93

Джерело: опрацьовано авторами

Щоденна волатильність показала середні результати. Цей метод є надійним, але може недооцінювати складні взаємозв'язки між факторами.

Метод High-Low продемонстрував найгірші показники. Це пов'язано з тим, що він ігнорує внутрішньоденні коливання ціни.

GARCH, ATR та Parkinson показали прийнятні результати, але методи машинного навчання перевершують їх за точністю прогнозів.

Здатність LSTM моделювати часові відношення робить його особливо ефективним для аналізу волатильності.

Random Forest виявився найточнішим методом. Random Forest враховує не тільки щоденні зміни цін, але й обсяги торгівлі та технічні індикатори. Це робить його більш адаптивним до складних ринкових умов.

Random Forest також є менш чутливим до викидів у порівнянні з іншими методами, що особливо важливо для аналізу волатильності криптовалют.

Таким чином, за точністю прогнозів методи машинного навчання перевершують класичні статистичні методи. Це підтверджує необхідність використання сучасних технологій для аналізу складних фінансових даних.

Визначену волатильність можна використовувати разом із Reinforcement Learning (RL) – галуззю машинного навчання, де агент навчається приймати рішення в середовищі, щоб максимізувати кумулятивну винагороду.

Основні компоненти RL: агент (Agent): той, хто приймає рішення або алгоритм, який вирішує, коли купувати або продавати;

середовище (Environment): світ, в якому діє агент, тобто ринок з історичними даними, поточними цінами тощо; дія (Action): крок, який робить агент; стан (State): опис поточного стану середовища; винагорода (Reward): сигнал, який агент отримує після виконання дії.

Загалом, RL-агент може допомогти знайти оптимальні параметри торгової стратегії, адаптуватися до змін на ринку в реальному часі, автоматично виконувати угоди на основі заданих правил, оптимізувати розподіл активів в портфелі тощо. RL-агент може допомогти розробити алгоритми, які автоматично приймають рішення про купівлю та продаж криптовалют на основі аналізу ринкових даних. Він у змозі допомогти оптимізувати розмір позицій та встановлювати стоп-лосси, щоб мінімізувати ризики; враховувати волатильність ринку та коригувати стратегію відповідно до рівня ризику. RL-агенти можуть допомогти виявляти та використовувати різницю цін на різних біржах, автоматично виконувати арбітражні операції, щоб отримати прибуток.

Але існують виклики використання RL на крипторинках – нестабільність даних, ризики перенавчання, висока конкуренція. На крипторинку існує багато алгоритмічних трейдерів, що ускладнює отримання прибутку.

Існують наступні типи алгоритмів RL, які використовуються в криптотрейдингу: Q-навчання (Q-learning) – це метод, який навчає агента вибирати дії, що максимізують очікувану винагороду; глибоке RL (Deep RL) поєднує RL з глибоким навчанням, що дозволяє агенту працювати з великими та складними просторами станів на основі використання нейронних мереж; методи Actor-Critic, які використовують дві нейронні мережі, такі як «actor» для визначення дії та «critic» для оцінки цих дій.

Можливе також використання гібридних методів, які об'єднують RL з іншими методами машинного навчання, такими як навчання з учителем і навчання без учителя. Використання RL в криптотрейдингу є перспективним напрямком, але вимагає глибокого розуміння технологій та ринку. Важливо ретельно тестувати стратегії та врахову-

вати ризики, пов'язані з волатильністю ринку.

Висновки. Дослідження виявило ключові аспекти прогнозування волатильності криптовалютних ринків, що мають важливе значення для інвесторів та трейдерів. Порівняльний аналіз семи методів розрахунку волатильності показав, що традиційні статистичні підходи мають своє обмеження в контексті сучасних складних ринкових умов. Алгоритми машинного навчання перевершили класичні методи за точністю прогнозів. Використання гібридних методів, що поєднують класичні статистичні моделі з алгоритмами машинного навчання, дає можливість зменшити нелінійність та асиметрію коливання ціни. Такий підхід особливо актуальний для оптимізації торгових стратегій та мінімізації ризиків у сучасному фінансовому аналізі криптовалют. У дослідженні також підкреслено перспективність застосування технологій навчання з підкріпленням (RL) для розробки автоматизованих торгово-аналітичних систем, які можуть адаптуватися до змін ринкових умов у реальному часі.

Література

1. Bouri, E., Saeed, E., Vinh Vo, X., and Roubaud, D. (2021). Quantile connectedness in the cryptocurrency market, *Journal of International Financial Markets, Institutions and Money*, Vol. 71, 101302. <https://doi.org/10.1016/j.intfin.2021.101302.2>.
2. Gupta, H., and Chaudhary, R. (2022). An Empirical Study of Volatility in Cryptocurrency Market. *Journal of Risk and Financial Management*. 15: 513. <https://doi.org/10.3390/jrfm15110513>
3. Time Series Analysis: Forecasting and Control, 5th Edition, by George E.P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung (2015). John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712.
4. Kejia, Y., Yan, H., and Gupta, R. (2022). Are GARCH and DCC values of 10 cryptocurrencies affected by COVID-19? *Journal of Risk and Financial Management*, 15(3), 113. <https://doi.org/10.3390/jrfm15030113>
5. Khedr, A.M., Arif, I., Pravija Raj, P.V., El-Bannany, M., Alhashmi, S.M., & Sreedharan, M. (2021). Cryptocurrency price prediction using traditional statistical and machine learning techniques: A survey. *Intelligent Systems in Accounting, Finance and Management*, 28(1), 3-34. <https://doi.org/10.1002/isaf.1488>
6. Bollerslev, Tim. Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics*, Volume 31, Issue 3, 1986, Pages 307-327, ISSN 0304-4076, [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1).
7. Henrique, B.M., Sobreiro, V.A., & Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction R. *Expert Systems*

with Applications, 124, 226-251. <https://doi.org/10.1016/j.eswa.2019.01.012>

8. Umar Yahaya, H., Sunday Oyinloye, J., & Olorunfemi Adams, S. (2022). Modeling and Forecasting Cryptocurrency Returns and Volatility: An Application of GARCH Models. *Universal Journal of Finance and Economics*, 2(1), 71-90. *Universal Journal of Finance and Economics*, 2022, 2, 497. <https://doi.org/10.31586/ujfe.2022.497>

9. Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons & Fractals*, 118, 35-40. <https://doi.org/10.1016/J.CHAOS.2018.11.014>

10. Nazareth, N., & Ramana Reddy, Y. V. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*, 219(January), 119640. <https://doi.org/10.1016/j.eswa.2023.119640>

References

1. Bouri, E., Saeed, E., Vinh Vo, X., and Roubaud, D. (2021). Quantile connectedness in the cryptocurrency market, *Journal of International Financial Markets, Institutions and Money*, Vol. 71, 101302. <https://doi.org/10.1016/j.intfin.2021.101302.2>.

2. Gupta, H., and Chaudhary, R. (2022)/ An Empirical Study of Volatility in Cryptocurrency Market. *Journal of Risk and Financial Management*. 15: 513. <https://doi.org/10.3390/jrfm15110513>

3. *Time Series Analysis: Forecasting and Control*, 5th Edition, by George E.P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung (2015). John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712.

4. Kejia, Y., Yan, H., and Gupta, R. (2022). Are GARCH and DCC values of 10 cryptocurrencies affected by COVID-19? *Journal of Risk and Financial Management*, 15(3), 113. <https://doi.org/10.3390/jrfm15030113>

5. Khedr, A. M., Arif, I., Pravija Raj, P. V., El-Bannany, M., Alhashmi, S. M., & Sreedharan, M. (2021). Cryptocurrency price prediction using traditional statistical and machine learning techniques: A survey. *Intelligent Systems in Accounting, Finance and Management*, 28(1), 3-34. <https://doi.org/10.1002/isaf.1488>

6. Bollerslev, Tim. Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics*, Volume 31, Issue 3, 1986, Pages 307-327, [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1).

7. Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction R. *Expert Systems with Applications*, 124, 226-251. <https://doi.org/10.1016/j.eswa.2019.01.012>

8. Umar Yahaya, H., Sunday Oyinloye, J., & Olorunfemi Adams, S. (2022). Modeling and Forecasting Cryptocurrency Returns and Volatility: An Application of GARCH Models. *Universal Journal of Finance and Economics*, 2(1), 71-90. *Universal Journal of Finance and Economics*, 2022, 2, 497 <https://doi.org/10.31586/ujfe.2022.497>

9. Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons & Fractals*, 118, 35-40. <https://doi.org/10.1016/J.CHAOS.2018.11.014>

10. Nazareth, N., & Ramana Reddy, Y. V. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*, 219(January), 119640. <https://doi.org/10.1016/j.eswa.2023.119640>

MODERN METHODS OF CRYPTOCURRENCY MARKET VOLATILITY PREDICTION

V. D. Kozenkova, Ph. D (Econ.), Associate Professor,

Dnipro State Agrarian and Economic University,

A. M. Movsesyants, Post-graduate Student, Ukrainian State University
of Science and Technology

Methods. The application of the abstraction method allowed for the isolation of volatility characteristics, simplifying the analysis of complex financial data of the cryptocurrency market. Analysis with synthesis facilitated the identification of patterns and the integration of traditional and modern forecasting approaches, providing a comprehensive assessment of methods. Logical and historical approaches enabled evolutionary analysis, while classification methods based on general and specific analysis principles, combined with comparative and abstract-logical analysis, allowed for an objective evaluation of the developed models' effectiveness and justified the feasibility of developing innovative solutions for optimizing trading strategies and minimizing risks.

Results. The study conducted a comparative analysis of cryptocurrency market volatility prediction methods using traditional statistical approaches and modern machine learning algorithms. The results confirm the advantages of integrating classical methods with machine learning algorithms, which allow for more accurate risk assessment and optimization of trading strategies in the highly volatile cryptocurrency markets. The determined volatility can be used in conjunction with Reinforcement Learning (RL) to optimize trading strategies, allowing an agent to learn to make decisions in an environment to maximize cumulative reward. The use of RL in cryptocurrency trading is a promising direction but requires a cautious approach and thorough testing of strategies before their application in real trading.

Novelty. The scientific novelty lies in a comprehensive approach to forecasting cryptocurrency market volatility, combining classical statistical methods with modern machine learning algorithms. The advantages of ensemble machine learning methods for analyzing cryptocurrency volatility have been established. The integration of Reinforcement Learning (RL) for optimizing trading strategies based on predicted volatility is proposed, representing a new approach to cryptocurrency trading automation.

Practical value. The research results have practical significance for cryptocurrency market participants, including investors, traders, and financial analysts. The integration of machine learning methods with traditional statistical approaches opens new opportunities for developing effective trading strategies, contributing to increased profitability and stability in the cryptocurrency market. The research is also useful for developers of trading platforms and analytical tools, as it provides empirical data for improving prediction algorithms and market data analysis.

Keywords: volatility, cryptocurrency, prediction, machine learning methods, GARCH, LSTM, Random Forest, Reinforcement Learning.

Надійшла до редакції 30.01.25 р.