

УДК 004.4:336.76

DOI: <https://doi.org/10.53920/ITS-2024-1-5>

Нікіта Андрійович ПУПОВ,

здобувач другого (магістерського) рівня вищої освіти,
Державний університет інфраструктури та технологій

ORCID ID: [0009-0004-1481-9540](https://orcid.org/0009-0004-1481-9540)

Ганна Анатоліївна ЗАВГОРОДНЯ,

кандидат технічних наук, доцент,
Державний університет інфраструктури та технологій

ORCID ID: [0000-0001-8523-1761](https://orcid.org/0000-0001-8523-1761)

ВИКОРИСТАННЯ МЕТОДУ ЛІНІЙНОЇ РЕГРЕСІЇ ДЛЯ ПРОГНОЗУВАННЯ КУРСУ КРИПТОВАЛЮТИ

Прогнозування курсу криптовалюти є однією з найбільш досліджуваних тем і викликає інтерес як з наукової, так і з комерційної точки зору. Колись для прогнозування трейдери використовували різні складні формули та графіки, аналізували їх, і на їх основі будували торгові стратегії. Зараз, з появою штучного інтелекту було задіяно різні алгоритми з метою прогнозування руху фондового ринку, включаючи різні криптовалюти.

Алгоритми машинного навчання використовуються як для передбачення ціни акцій на близький період, так і для розуміння ринку у довгостроковій перспективі. На даний момент у відкритому доступі досить багато досліджень використання штучного інтелекту для прогнозування ринку з низькою волатильністю, таких як індекси, або акції міжнародних компаній. Проте, все ще мало досліджень описують прогнозування ринку високої волатильності, такого як ринку криптовалют. Ці ринки відомі своєю непередбачуваністю і складністю, що робить їх цікавими для дослідників та трейдерів.

У цій статті досліджується застосування методу лінійної регресії для прогнозування ціни на фондовому ринку високої волатильності, такому як ринок криптовалют. Для даного дослідження було обрано криптовалюту Ethereum. Автор аналізує вплив різних вхідних даних, таких як історія цін, обсяги торгівлі та інші технічні індикатори, на результативність моделі. Також, порівнюється вплив різних параметрів моделі на якість результатів і час її тренування.

Крім того, пропонується торгова стратегія, побудована на основі передбачень моделі, та описується результат її роботи в симуляції криптовалютного ринку. Аналіз результатів показує переваги та недоліки використання лінійної регресії для передбачення ринку високої волатильності. У підсумку автор визначає доцільність використання такої моделі для реальної торгівлі та пропонує способи покращення точності передбачень.

Ключові слова: лінійна регресія, штучний інтелект, криптовалюта, прогнозування ціни на криптовалюту, Ethereum, ринок високої волатильності.

Nikita PUPOV,

Master's student,

State University of Infrastructure and Technologies

Anna ZAVGORODNYA,

Candidate of technical sciences, Associate Professor,

State University of Infrastructure and Technologies

USE OF LINEAR REGRESSION METHOD FOR CRYPTOCURRENCY PRICE PREDICTION

Predicting cryptocurrency prices is one of the most researched topics and is of interest both scientifically and commercially. In the past, traders used various complex formulas and charts for forecasting, analyzed them, and based on their findings, built trading strategies. Now, with the advent of artificial intelligence, various algorithms have been employed to predict stock market movements, including various cryptocurrencies.

Machine learning algorithms are used both for short-term stock price prediction and for long-term market understanding. At present, there are quite a few studies in the public domain on the use of artificial intelligence for predicting markets with low volatility, such as indices or international company stocks. However, there are still few studies describing the prediction of high-volatility markets, such as the cryptocurrency market. These markets are known for their unpredictability and complexity, making them interesting for researchers and traders.

This article explores the application of the linear regression method for predicting prices in a high-volatility stock market, such as the

cryptocurrency market. For this study, the cryptocurrency Ethereum was chosen. The author analyzes the impact of various input data, such as price history, trading volumes, and other technical indicators, on the model's performance. Additionally, the impact of different model parameters on the quality of results and training time is compared.

Moreover, a trading strategy based on the model's predictions is proposed, and the results of its performance in a cryptocurrency market simulation are described. The analysis of the results shows the advantages and disadvantages of using linear regression for predicting high-volatility markets. In conclusion, the author determines the feasibility of using such a model for real trading and suggests ways to improve prediction accuracy.

Keywords: linear regression, artificial intelligence, cryptocurrency, cryptocurrency price forecasting, Ethereum, high-volatility market.

Постановка проблеми. З появою фондового ринку, як науковці, так і трейдери намагалися знайти шляхи мінімізації торговельного ризику і збільшення доходності торгівлі на фондовому ринку. Раніше для передбачення ринку використовували складні формули та аналізували графіки. Але, з розвитком галузі штучного інтелекту, все більше трейдерів використовують різні алгоритми для аналізу великих об'ємів ринкових даних, та використовують їх результати в своїй роботі. Різке збільшення наукових робіт що досліджують цю сферу також є показником її швидкого розвитку.

Прогнозування фондового ринку є нетривіальною задачею через його непередбачуваність. Згідно з теорії випадкового блукання [1], ціни на фондовому ринку рухаються непередбачувано, тому минулі показники не можуть бути використані для точного прогнозування майбутніх цін. Однак, багато економістів не повністю підтримують цю теорію. Вони схиляються до того що неможливо стабільно передбачати ринок саме у довгостроковій перспективі.

Незважаючи на велику кількість наукових досліджень, що вивчають застосування методів штучного інтелекту для прогнозування фондового ринку низької волатильності, існує обмежена кількість досліджень, що розглядають ринки високої волатильності, такі як ринок криптовалют. Саме тому дослідження на ринках високої волатильності є досить актуальними.

Аналіз останніх досліджень і публікацій. У статті [2], автори досліджували поведінку фондового ринку і порівнювали різні алгоритми, до яких входили Random Forest (RF), Support Vector Machine (SVM), Naive Bayes, K-Nearest Neighbor (KNN), та Softmax для передбачення цін на акції. Автори використовували дані з різних джерел (Yahoo, NSE-India), провели порівняльний аналіз цих підходів. Як результат, було виявлено що RF дав найбільш задовільні результати для великого датасету. Тоді як Naive Bayes гарно себе показав на малому датасеті. Ще одне спостереження полягало в тому, що зі зменшенням кількості технічних показників, точність моделей знижувалася.

Дослідження Мегхни Місри [3] показало, що прогнози зроблені лінійною регресією мають покращену точність після використання алгоритму аналізу головних компонентів (PCA) для вибору найважливіших даних із датасету. SVM демонстрував високу точність на нелінійній вибірці, лінійна регресія краще працювала ж на лінійній вибірці. У порівнянні, багатосаровий перцептрон (MLP) показав найменшу помилку в прогнозуванні.

Також, деякі автори пропонують використовувати аналіз настроїв для покращення результатів передбачення, адже не секрет, що ціна на акції сильно залежить від настроїв інвесторів.

Мета статті – дослідження застосування методу лінійної регресії для прогнозування ціни криптовалюти Ethereum. Дослідити вплив вхідних даних та параметрів моделі на точність передбачення. Також, створення торгової стратегії на основі отриманих передбачень та перевірка її роботи в симуляції ринку.

Виклад основного матеріалу дослідження. Як правило, для прогнозування ціни на фондовому ринку використовують три основні види аналізу:

1. Технічний аналіз [4]. У цьому виді аналізу трейдери аналізують минулі ціни та обсяги угод, використовуючи графіки та інші інструменти для виявлення патернів та закономірностей. Для цієї задачі використовується безліч спеціально створених для цього індикаторів: Moving Average, Standard Deviation, Average Directional Index, Ichimoku Kinko Hyo, Accumulation Swing Index, Bollinger Bands та інші.

2. Фундаментальний аналіз [5]. Для цього виду аналізу вивчають фінансово-економічну інформацію яка може впливати на динаміку активу або фінансового інструменту. Наприклад, аналі-

зують фінансові звіти компаній, стан індустрії чи економіки певної країни. На основі цих даних трейдери визначають чи є акції переоціненими або недооціненими.

3. Аналіз настроїв [6]. Трейдери аналізують ринок, щоб зрозуміти настрої інвесторів. Для цього аналізуються різні джерела громадських думок: новини, соціальні мережі та інші.

Для дослідження буде використано тільки технічний аналіз, адже збір і структурування даних для інших видів аналізу становить непросту задачу і не завжди можуть бути автоматизовані.

Використані інструменти і джерела даних. У даному дослідженні використовується мова програмування Python. Бібліотека sklearn використовується для роботи з аналітичними моделями, в даному випадку це лінійна регресія. Для роботи з датасетом використовується Pandas, а для побудови графіків – matplotlib.

Щоб отримати технічні дані для криптовалюти Ethereum був використаний Binance API. Середовище для запуску алгоритму – google colab.

Дані та їх обробка. Використовуючи Binance API було отримано технічні дані криптовалюти Ethereum. Отримані дані представляють характеристику пари ETHUSDT, що показує торги криптовалюти Ethereum за криптовалюту USDT, яка є аналогом валюти USD і має таку саму ціну як і USD. Самі дані агреговані по годинно і знаходяться в часовому інтервалі з 2019-11-27 по 2024-05-19, що відповідає всім наявним історичним даним криптовалюти Ethereum. Приклад даних зображено на рисунку 1.

Як можна побачити, ми маємо інформацію про 39234 погодинних інтервалів цієї криптовалюти. Ці дані містять такі параметри:

- datetime – час початку інтервалу. Якщо datetime має значення 2019-11-27 07-00-00, це означає що інтервал описує параметри криптовалюти в періоді з 2019-11-27 07-00-00 по 2019-11-27 08-00-00;
- open – ціна криптовалюти на момент початку періоду;
- high – найбільша ціна криптовалюти за період;
- low – найменша ціна криптовалюти за період;
- close – ціна криптовалюти на момент закінчення періоду;
- volume – обсяг торгів, тобто кількість криптовалюти яка була куплена або продана протягом періоду;
- quoteAssetVolume – обсяг торгів у валюті USDT протягом періоду;

- numberOfTrades – кількість угод протягом періоду;
- takerBuyQuoteVol – обсяг криптовалюти, купленої за точною ціною.

dateTime	open	high	low	close	volume	quoteAssetVolume	numberOfTrades	takerBuyQuoteVol
2019-11-27 07-00-00	146.00	146.00	146.00	146.00	0.010	1.460000e+00	1	0.000000e+00
2019-11-27 08-00-00	125.03	145.01	125.03	133.00	0.080	1.092040e+01	5	1.450100e+00
2019-11-27 09-00-00	133.00	133.00	133.00	133.00	0.000	0.000000e+00	0	0.000000e+00
2019-11-27 10-00-00	142.20	144.52	142.10	142.62	2832.710	4.040542e+05	387	3.702431e+05
2019-11-27 11-00-00	142.70	146.92	142.22	146.58	9079.800	1.312100e+06	1107	8.536526e+05
...
2024-05-18 20-00-00	3118.40	3125.96	3112.72	3118.20	34026.549	1.061726e+08	60371	5.268436e+07
2024-05-18 21-00-00	3118.20	3120.54	3103.99	3114.81	28708.583	8.937320e+07	58639	4.025525e+07
2024-05-18 22-00-00	3114.80	3125.15	3112.10	3116.65	22156.588	6.907781e+07	47650	3.515870e+07
2024-05-18 23-00-00	3116.65	3123.51	3114.04	3121.59	18141.217	5.659744e+07	43209	2.695123e+07
2024-05-19 00-00-00	3121.60	3124.30	3111.50	3112.00	23645.387	7.374108e+07	51500	3.049573e+07

39234 rows x 8 columns

Рис. 1. Технічні дані криптовалюти Ethereum [10]

Опис лінійної регресії. У статистиці лінійна регресія [7] – це статистичний метод для вивчення залежності між змінними x та y шляхом побудови лінійної моделі, яка найкращим чином апроксимує спостережувані дані. Вона використовується для прогнозування значень залежної змінної y на основі однієї або кількох незалежних змінних x шляхом мінімізації суми квадратів відхилень між фактичним та передбаченими значеннями.

Загальна модель лінійної регресії має такий вигляд:

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + u, \quad (1)$$

де y – залежна змінна, (x_1, x_2, \dots, x_k) – незалежні змінні, u – випадкова похибка, $(\beta_1, \beta_2, \dots, \beta_k)$ – вектор параметрів моделі. Задача лінійної регресії полягає в оцінці цих параметрів на основі деяких експериментальних даних y та (x_1, x_2, \dots, x_k) .

Формула оцінювання в лінійній регресії базується на методі найменших квадратів (МНК) [8], який використовується для знаходження лінії (або гіперплощини в багатовимірній регресії), що найкращим чином підходить до емпіричних даних. Формула МНК має вигляд:

$$b_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad (2)$$

$$b_0 = \bar{y} - b_1 \bar{x}, \quad (3)$$

де n – кількість спостережень, x_i та y_i – значення незалежної та залежної змінних відповідно до i -го спостереження, \bar{x} та \bar{y} – середні значення незалежної та залежної змінних відповідно. Коефіцієнти b_1 та b_0 обчислюються так, щоб мінімізувати суму квадратів відхилень між фактичними значеннями залежної змінної та її прогнозованими значеннями.

Для моделі лінійної регресії будемо використовувати модель ElasticNet бібліотеки sklearn.

Процес тренування моделі. Для тренування моделі вхідні дані будуть розподілені на дві частини. Перша частина буде складатися з 85% історичних даних і буде використовуватися для тренування моделі. Друга частина буде складатися з 15% історичних даних і буде використовуватися для передбачення моделі і оцінки її результатів. А також для симуляції торгової стратегії.

Важливо зауважити, що дані для тренування моделі обов'язково повинні бути хронологічно раніше даних які використовуються для оцінки моделі, адже якщо зробити інакше, то тренуючись, модель буде знати про дані з оціночного датасету. Хоча й модель буде робити надто точні передбачення, така модель не буде працювати в реальних умовах, адже коли ми тренуємо модель в реальних умовах, дані які вона передбачає завжди йдуть пізніше тих даних на яких вона вчиться [9].

Оцінка роботи моделі. Модель буде передбачати показник *average*, що показує середню ціну криптовалюти за період і рахується за такою формулою для кожного періоду:

$$average = quoteAssetVolume / volume \quad (4)$$

Таким чином, для оцінки роботи моделі порівнюється реальний *average* поточного інтервалу з передбачуваним *average*. Маючи результати, обчислюється середня абсолютна похибка (MAE), середня квадратична похибка (MSE), середня абсолютна відсоткова похибка (MAPE), а також відсоток значень *average*, що були досягнуті в періоді (коли *average* знаходиться між *low* та *high*).

Аналіз впливу різних вхідних даних на результативність моделі. Для аналізу впливу різних вхідних даних на результативність моделі, готуються різні датасети:

1. Складає вхідні дані, зображені на рисунку 1, та підрахований *average*

2. Складає вхідні дані, зображені на рисунку 1, підрахований *average*, та додаткові технічні показники як EMA, SMA, BBL, BBM, VBU, BBB, BBP, RSI, OBV.

3. Складає вхідні дані, зображені на рисунку 1, підрахований *average*, додаткові технічні показники як EMA, SMA, BBL, BBM, VBU, BBB, BBP, RSI, OBV. Також датасет матиме значення відношення середнього значення параметра (*open, close, low, high, average*) за попередні періоди в 2, 4, 16, 32, 128, 256 годин до поточного *average*.

Далі наведена таблиця порівняння цих датасетів і оцінки роботи моделі:

Таблиця 2. Порівняння датасетів

Номер датасету	MAE	MSE	MAPE	Відсоток <i>average</i> між <i>low</i> та <i>high</i>
1	13.0558	462.364	0.00487	52.1%
2	12.2050	411.796	0.00452	52.7%
3	11.4621	322.998	0.00426	53.8%

Таким чином, можна побачити, що датасет з додатковими технічними показниками дає кращі результати, ніж без них. А найкраще модель працює з датасетом, який має відношення значень до значень з попередніх інтервалів. Ймовірно, цей датасет показує кращі результати, бо додаткові змінні встановлюють відношення до попередніх інтервалів і модель бачить картину параметрів не тільки за поточний інтервал, але й за минулі інтервали. Надалі будемо використовувати цей датасет.

Порівняння впливу різних параметрів моделі на якість прогнозів та час тренування. Модель ElasticNet має декілька параметрів, які можуть впливати на результат виконання: *alpha, max_iter, tol*. Використаємо GridSearch для знаходження найбільш опти-

мальних параметрів. Цей алгоритм перебирає всі задані варіанти параметрів і знаходить найбільш оптимальні з них. За результатом його виконання, було виявлено найоптимальніші параметри α та tol . Однак, було помічено, що зі збільшенням параметра max_iter , покращується точність результатів, а також і час тренування моделі, адже цей параметр відповідає за кількість ітерацій. Побудуємо графік залежності MSE (рис. 2) та часу тренування моделі від значення max_iter (рис. 3).




Рис. 2. Залежність MSE від max_iter




Рис. 3. Залежність часу тренування від max_iter

Як можна побачити, MSE прямує приблизно до 160. А зі збільшенням max_iter , час виконання збільшується лінійно. Тож для досліджуваної моделі було вирішено взяти значення $max_iter = 150000$.

Опис простої торгової стратегії на основі передбачень моделі. Тож, фінальна модель передбачає середню ціну криптовалюти Ethereum на наступний період в одну годину з такою точністю: $MAE=7.5455$,

MSE=160.255, MAPE=0.0028. Відсоток передбачень, де передбачуване значення входить в інтервал між *low* та *high*, становить 96.28%.

Таким чином, беручи до уваги комісію торгової платформи Binance за операцію в 0,01% від суми операції, була запропонована торгова стратегія, що використовує ф'ючерси і виглядає так:

1. Якщо передбачуване значення *average* відрізняється від поточної ціни (значення *open*) криптовалюти менше ніж в 0,01%, нічого не робимо, адже в такому випадку навіть якщо ціна криптовалюти дійде до *average*, то через комісію ми втратимо гроші.

2. Якщо передбачуване значення *average* більше за значення поточної ціни (значення *open*) криптовалюти, ми купуємо ф'ючерс криптовалюти і продаємо її коли ціна криптовалюти дійде до передбачуваного значення (торгівля в довгу).

3. Якщо передбачуване значення *average* менше за значення поточної ціни (значення *open*) криптовалюти, ми продаємо ф'ючерс криптовалюти і купуємо її коли ціна криптовалюти дійде до передбачуваного значення (торгівля в коротку).

4. Якщо за весь час періоду вартість криптовалюти не досягла передбачуваного значення, ми продаємо ф'ючерси за кінцевою ціною в періоді (значення *close*).

За умови, якщо на початку торгів ми маємо 100 USDT на рахунку та використовуємо всі наявні кошти для кожного інтервалу, маємо такий графік зміни балансу з часом (рис. 4).




Рис. 4. Зміна поточного балансу

Тож, маючи 100 USDT на початку торгів, через пів року торгів на основі передбачуваних значень, залишок становитиме 97.69 USDT. Отже, незважаючи на відносно високу точність передбачень моделі, використовувати її для торгівлі не вигідно.

Висновки та пропозиції. У наведеному дослідженні була знайдена найоптимальніша модель лінійної регресії, що досить точно передбачає середнє значення ціни на криптовалюту. Також, було створено симуляцію трейдингової платформи, за результатами якої було зроблено висновок, що за рахунок незначної кількості неправильних передбачень, втрата грошей є досить значною. Тому, дану модель не вигідно використовувати для торгівлі.

Для покращення передбачень моделі можна використати інший алгоритм, такий як Naive Bayes, K-Nearest Neighbor, Random Forest, Support Vector Machine, та інші. Також, покращити результат роботи моделі може додаткова аналітична інформація, така як аналіз настроїв. Спираючись на раніше згадані дослідження, поєднуючи технічний аналіз та аналіз настроїв, можна досягти вищої точності передбачення.

© Пуов Н.А., Завгородня Г.А., 2024

ЛІТЕРАТУРА

1. Malkiel, B. G. «The Efficient Market Hypothesis and Its Critics». *The Journal of Economic Perspectives*, 17(1). 2003. P 59-82.
2. Kumar, I., Dogra, K., Utreja, C., & Yadav, P. A comparative study of supervised machine learning algorithms for stock market trend prediction. In 2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT). 2018. P. 1003-1007. IEEE.
3. Misra, M., Yadav, A. P., & Kaur, H. «Stock Market Prediction using Machine Learning Algorithms: A Classification Study». In 2018 International Conference on Recent Innovations in Electrical, Electronics & Communication Engineering (ICRIEECE). 2018. P. 2475-2478. IEEE.
4. Pring, M. J. «Technical Analysis Explained: The Successful Investor's Guide to Spotting Investment Trends and Turning Points». New York: McGraw-Hill Education. 2014. ISBN: 9780071825170.
5. Damodaran, A. «Investment Valuation: Tools and Techniques for Determining the Value of Any Asset». Hoboken, NJ: John Wiley & Sons. 2012. ISBN: 9781118011522.
6. Li, X., Xie, H., Wang, R., Cai, Y., Cao, J., & Min, H. «Empirical Analysis: Stock Market Prediction via Natural Language Processing and Social Media». In Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence. AAAI Press 2016.
7. Montgomery, D. C., Peck, E. A., & Vining, G. G. «Introduction to Linear Regression Analysis». Hoboken, NJ: John Wiley & Sons. 2012. ISBN: 9780470542811.
8. Seber, G. A. F., & Lee, A. J. «Linear Regression Analysis». Hoboken, NJ: John Wiley & Sons. 2012. ISBN: 9780470584255.

9. Завгородній В.В., Завгородня Г.А., Валявська Н.О., Герасименко О.О. Калюжний О.В., Степовий А.В. Пошук аномалій у даних за допомогою машинного навчання. *Вчені записки Таврійського національного університету імені В. І. Вернадського. Серія: Технічні науки*. Том 33 (72). №3, 2022. С. 39-43. DOI https://tech.vernadskyjournals.in.ua/journals/2022/3_2022/6.pdf.

10. <https://binance-docs.github.io/apidocs/futures/en/#kline-candlestick-data>.

REFERENCES

1. Malkiel, B. G. «The Efficient Market Hypothesis and Its Critics». *The Journal of Economic Perspectives*, 17(1). 2003. P. 59-82.

2. Kumar, I., Dogra, K., Utreja, C., & Yadav, P. A comparative study of supervised machine learning algorithms for stock market trend prediction. *In 2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT)*. 2018. P. 1003-1007. IEEE.

3. Misra, M., Yadav, A. P., & Kaur, H. «Stock Market Prediction using Machine Learning Algorithms: A Classification Study». *In 2018 International Conference on Recent Innovations in Electrical, Electronics & Communication Engineering (ICRIEECE)*. 2018. P. 2475-2478. IEEE.

4. Pring, M. J. «Technical Analysis Explained: The Successful Investor's Guide to Spotting Investment Trends and Turning Points». New York: McGraw-Hill Education. 2014. ISBN: 9780071825170.

5. Damodaran, A. «Investment Valuation: Tools and Techniques for Determining the Value of Any Asset». Hoboken, NJ: John Wiley & Sons. 2012. ISBN: 9781118011522.

6. Li, X., Xie, H., Wang, R., Cai, Y., Cao, J., & Min, H. «Empirical Analysis: Stock Market Prediction via Natural Language Processing and Social Media». *In Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence*. AAAI Press 2016.

7. Montgomery, D. C., Peck, E. A., & Vining, G. G. «Introduction to Linear Regression Analysis». Hoboken, NJ: John Wiley & Sons. 2012. ISBN: 9780470542811.

8. Seber, G. A. F., & Lee, A. J. «Linear Regression Analysis». Hoboken, NJ: John Wiley & Sons. 2012. ISBN: 9780470584255.

9. Zavgorodnii V.V., Zavgorodnya A.A., Valyavska N.O., Gerasimenko O.O., Kalyuzhny O.V., Stepovy A.V. (2022). Poshuk anomaliiy u danykh za dopomohoyu mashynnoho navchannya [Searching for anomalies in machine learning data]. *Vcheni zapysky Tavriys'koho natsional'noho universytetu imeni V. I. Vernads'koho. Seriya: Tekhnichni nauky. - Scholarly notes of V. I. Vernadsky Tavri National University. Series: Technical sciences. Vol. 33 (72). №3, 39-43 [in Ukrainian]*. DOI https://tech.vernadskyjournals.in.ua/journals/2022/3_2022/6.pdf

10. <https://binance-docs.github.io/apidocs/futures/en/#kline-candlestick-data>.

СТАТТЯ НАДІЙШЛА ДО РЕДАКЦІЇ 07.06.2024