

# Comparing the Results of Neural Networks in Predicting Cryptocurrency Prices Under Risk Conditions

1. MohammadDaniyal Jahed<sup>1</sup>: Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran

2. Zadolah Fathi<sup>2\*</sup>: Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. Email: zad.fathi@iauctb.ac.ir (Corresponding Author)

3. Gholamreza Zomorodian<sup>3</sup>: Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran

## Article history



Received: 29 April 2024

Revised: 31 July 2024

Accepted: 08 August 2024

Published: 20 September 2024

## Abstract:

This study aimed to compare the performance of different neural networks in predicting cryptocurrency prices, with a focus on Bitcoin, under risk conditions. The research was applied and descriptive-analytical in nature. Historical data of Bitcoin, Ethereum, and Ripple from 2018 to 2023 were collected from reliable exchanges and financial platforms. After preprocessing, the data were divided into training and testing sets. Two neural network models, Multilayer Perceptron (MLP) and Radial Basis Function (RBF), were designed and implemented. Model performance was evaluated using error measurement indices including Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and the coefficient of determination ( $R^2$ ). The results indicated that the MLP model outperformed the RBF model in prediction accuracy. The coefficient of determination reached 99.5% for MLP and 98.9% for RBF. Comparative analysis of error metrics showed significant reductions in RMSE and MAE in the MLP model compared to RBF. Moreover, the proposed Multi-Input Deep Learning (MICDL) model surpassed comparative CNN-LSTM models in classifying short-term price movements, particularly in directional prediction accuracy. Neural networks, especially the MLP model, demonstrated high accuracy and flexibility in forecasting cryptocurrency price fluctuations. These models can serve as effective tools for investors, analysts, and policymakers in risk management and informed decision-making. However, incorporating more diverse and real-time data along with hybrid deep learning techniques could further enhance predictive performance in future studies.

**Keywords:** Bitcoin, price prediction, artificial neural network, Multilayer Perceptron (MLP), Radial Basis Function (RBF).



## Extended Abstract

## Introduction

The rapid evolution of financial technologies in recent decades has fundamentally transformed global investment landscapes. Among these technologies, cryptocurrencies such as Bitcoin, Ethereum, and Ripple have emerged as influential assets with substantial impact on digital transactions, portfolio diversification, and economic policymaking (Shahnavazi et al., 2022). However, the cryptocurrency market is characterized by extremely high volatility and unpredictability, posing substantial challenges to investors, policymakers, and researchers alike (Torabi, 2021). Thus, developing reliable forecasting models has become a central focus of contemporary financial research.

Traditional statistical models, including ARIMA and GARCH, have been widely applied in financial forecasting, yet their ability to capture the nonlinear, dynamic, and highly stochastic behavior of cryptocurrencies is limited (Abusaleh Mohammadsharifi et al., 2021). In contrast, artificial intelligence (AI)-based approaches, particularly machine learning (ML) and deep learning (DL), have shown superior performance in modeling nonlinearities and extracting hidden patterns from large-scale financial datasets (Akouaouch & Bouayad, 2025). Studies have emphasized that hybrid models combining time-series decomposition with DL can significantly enhance forecasting accuracy (Sayadi Nejad et al., 2023), while fuzzy neural networks have demonstrated effectiveness under environmental uncertainty (Darvish Motavalli & Amini, 2023).

Recent contributions also highlight the role of attention mechanisms and transfer learning in refining model adaptability and accuracy. For instance, (Yeganeh et al., 2025) showed that incorporating attention layers improves predictive accuracy and supports automated trading strategies for Ethereum. Similarly, (Jahanbin & Chahooki, 2025) illustrated how hybrid deep transfer learning can enhance trend prediction by transferring knowledge across similar domains. Ensemble methods further strengthen predictive performance by minimizing forecasting errors and stabilizing results across different datasets (Kiranmai Balijepalli & Thangaraj, 2025; Song, 2025).

Beyond pure prediction, studies have addressed the integration of economic and social data to improve model robustness. For example, (Ghorbani et al., 2022) applied sentiment analysis on social media and celebrity endorsements, while (Nouira et al., 2024) reviewed how social networks combined with ML enhance forecasting accuracy. These findings align with the argument that incorporating multidimensional features—economic, social, and technological—is crucial to understanding cryptocurrency price dynamics (Lari & Nikseresht, 2020). Moreover, the relationship between cryptocurrencies and other markets, such as oil and gold, has been explored to identify inter-market dependencies. (Ibrahim et al., 2025), for example, demonstrated that cryptocurrencies could predict oil prices before and during the COVID-19 pandemic, confirming the systemic links across asset classes.

Other lines of research have emphasized the role of anomaly detection and fraud prevention. (Das et al., 2025) explored scam detection patterns in the U.S. market using ML, while (Crisostomo et al., 2025) reviewed ML approaches for detecting vulnerabilities in Ethereum smart contracts. These perspectives illustrate that accurate forecasting not only informs investment strategies but also strengthens trust, resilience, and stability within the cryptocurrency ecosystem (Alnami et al., 2025).

Overall, the literature highlights three key directions: (a) the need for advanced deep learning models to outperform classical methods, (b) the integration of multi-source data including economic indicators and social signals, and (c) the importance of anomaly detection and systemic risk analysis. Despite the progress, gaps remain in leveraging hybrid DL

approaches that combine technical, economic, and behavioral factors in unified forecasting frameworks (Tabyanian & Farsian, 2020; Torabi et al., 2020). The present study addresses this gap by proposing a multi-input deep learning (MICDL) model and comparing it against benchmark CNN-LSTM architectures in predicting Bitcoin, Ethereum, and Ripple prices under conditions of market volatility.

### Methods and Materials

This study employed a quantitative, applied, and analytical research design to forecast cryptocurrency prices. Historical data for Bitcoin (BTC), Ethereum (ETH), and Ripple (XRP) spanning from 2018 to 2025 were collected from authoritative financial platforms and exchange datasets. Preprocessing steps included data cleaning, normalization, and transformation to ensure consistency and comparability.

The dataset was split into training and testing subsets to validate predictive performance. The research tested three different deep learning architectures: Multilayer Perceptron (MLP), Radial Basis Function (RBF), and a newly proposed Multi-Input Deep Learning (MICDL) model. The latter was benchmarked against two CNN-LSTM hybrid models, referred to as Model1 and Model2.

Lag features were constructed with two temporal windows: 7 days (weekly) and 14 days (biweekly). Hyperparameter optimization was conducted through iterative trial-and-error, tuning convolutional filters, LSTM units, dense layer neurons, and dropout rates.

To evaluate regression performance, three standard metrics were employed: Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and the coefficient of determination ( $R^2$ ). In addition, classification metrics were used to assess the ability of models to predict the directional movement of prices. Specifically, the geometric mean (GM), sensitivity (Sen), and specificity (Spe) were computed to evaluate classification balance and robustness.

Correlation analysis was further conducted to assess relationships between cryptocurrency prices and macroeconomic indicators such as inflation (Iran, USA), exchange rates (Euro/USD), gold and oil prices, consumer indices, and government debt levels. Outlier analysis using Minitab 16 confirmed the absence of significant anomalies in the dataset, ensuring its suitability for robust modeling.

### Findings

The descriptive statistics showed high volatility in BTC, ETH, and XRP prices, consistent with the known nature of cryptocurrency markets. Table 1 presented means, medians, standard deviations, skewness, and kurtosis values, while Table 2 highlighted the proportions of upward and downward movements, confirming the dynamic and unpredictable behavior of these assets.

Regression results indicated that MLP consistently outperformed RBF in predictive accuracy, achieving lower MAE and RMSE values and higher  $R^2$  scores across all three cryptocurrencies.

When comparing MICDL to CNN-LSTM models, the regression performance across models was largely similar, with close MAE, RMSE, and  $R^2$  values. However, differences emerged in classification tasks. MICDL and Model2 significantly outperformed Model1 in predicting directional movements across both Lag = 7 and Lag = 14. For instance, under Lag = 7, MICDL achieved GM scores of 30.886, 29.582, and 25.053 for BTC, ETH, and XRP respectively, surpassing both Model1 and Model2. With Lag = 14, MICDL again outperformed with GM scores of 29.173, 30.461, and 26.157.

Correlation analysis revealed strong associations between cryptocurrency prices and macroeconomic indicators. Notably, Iranian inflation (0.82), government budget deficit (0.84), U.S. consumer index (0.81), gold price (0.91), and U.S. government debt (0.84) were highly correlated with cryptocurrency dynamics. These results confirm that macroeconomic shocks play a critical role in shaping cryptocurrency price trajectories.

Outlier detection via Minitab 16 boxplot analysis confirmed no significant anomalies, validating data integrity for subsequent modeling.

### Discussion and Conclusion

The findings of this study underscore the effectiveness of advanced deep learning models in forecasting cryptocurrency prices under volatile conditions. The superior performance of MLP over RBF validates earlier evidence that deep architectures capture nonlinear relationships more effectively than simpler neural structures (Aboutalebi et al., 2020; Hashimian & Akhavan Niaki, 2020). Similarly, the competitive advantage of MICDL over CNN-LSTM in classification tasks confirms the potential of multi-input designs to integrate diverse features and achieve higher predictive accuracy (Jahanbin & Chahooki, 2025; Yeganeh et al., 2025).

These results align with prior studies emphasizing hybrid and ensemble approaches. For example, (Kiranmai Balijepalli & Thangaraj, 2025) demonstrated that ensemble ML algorithms reduce forecasting errors, while (Song, 2025) highlighted their application in risk-adjusted portfolio optimization. The improved classification performance observed here supports these arguments and reinforces the value of hybridized architectures.

The role of macroeconomic variables identified in this study also reflects broader findings in the literature. (Ibrahim et al., 2025) confirmed the predictive role of cryptocurrencies in oil markets, while (Khonsarian et al., 2020) underscored their integration in portfolio strategies involving financial assets. The high correlations with inflation, consumer indices, and government debt observed in this research further establish the interdependence between cryptocurrencies and broader economic systems.

Finally, the findings resonate with perspectives highlighting the multidimensional nature of cryptocurrency markets. Studies linking social media sentiment to price fluctuations (Ghorbani et al., 2022; Nouira et al., 2024) and those emphasizing anomaly detection (Crisostomo et al., 2025; Das et al., 2025) suggest that robust forecasting frameworks must account for technical, economic, and behavioral dimensions. By validating the MICDL model against CNN-LSTM benchmarks, this study advances this agenda and illustrates a pathway toward more resilient, multidimensional forecasting systems.

In conclusion, the study provides strong evidence that deep learning architectures, particularly MICDL, hold promise for enhancing cryptocurrency price prediction. These models not only improve predictive accuracy but also offer insights into macroeconomic dependencies, thereby informing investment strategies and policymaking.

### Authors' Contributions

Authors equally contributed to this article.

### Acknowledgments

Authors thank all participants who participate in this study.

**Declaration of Interest**

The authors report no conflict of interest.

**Funding**

According to the authors, this article has no financial support.

**Ethical Considerations**

All procedures performed in this study were under the ethical standards.

# مقایسه نتایج حاصل از شبکه‌های عصبی در پیش‌بینی قیمت رمزارزها در شرایط ریسک



## تاریخچه مقاله

تاریخ دریافت: ۱۰ اردیبهشت ۱۴۰۳

تاریخ بازنگری: ۱۰ مرداد ۱۴۰۳

تاریخ پذیرش: ۱۸ مرداد ۱۴۰۳

تاریخ انتشار: ۳۰ شهریور ۱۴۰۳

۱. محمددانیال جاهد<sup>ID</sup>: گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

۲. زاداله فتحی<sup>ID\*</sup>: گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. ایمیل: [zad.fathi@iauctb.ac.ir](mailto:zad.fathi@iauctb.ac.ir) (نویسنده مسئول)

۳. غلامرضا زمردیان<sup>ID</sup>: گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

## چکیده

این پژوهش با هدف مقایسه عملکرد شبکه‌های عصبی مختلف در پیش‌بینی قیمت رمزارزها به‌ویژه بیت‌کوین در شرایط ریسک انجام شد. پژوهش حاضر از نوع کاربردی و توصیفی-تحلیلی است. داده‌های تاریخی مرتبط با قیمت و شاخص‌های کلیدی بیت‌کوین، اتریوم و رپل در بازه زمانی ۲۰۱۸ تا ۲۰۲۳ از منابع معتبر صرافی‌ها و پلتفرم‌های مالی گردآوری شد. داده‌ها پس از پیش‌پردازش به دو بخش آموزش و آزمون تقسیم شدند. دو مدل شبکه عصبی پرسپترون چندلایه (MLP) و توابع پایه شعاعی (RBF) طراحی و اجرا گردید. برای ارزیابی عملکرد مدل‌ها، معیارهایی چون میانگین قدر مطلق خطا (MAE)، جذر میانگین مربعات خطا (RMSE) و ضریب تعیین ( $R^2$ ) محاسبه شد. نتایج نشان داد مدل MLP نسبت به مدل RBF عملکرد دقیق‌تری در پیش‌بینی قیمت رمزارزها دارد. ضریب تعیین برای MLP برابر با ۹۹.۵٪ و برای RBF برابر با ۹۸.۹٪ به‌دست آمد. مقایسه معیارهای خطای بیانگر کاهش قابل‌توجه RMSE و MAE در مدل MLP نسبت به مدل RBF بود. همچنین، مدل پیشنهادی چندورودی عمیق (MICDL) در پیش‌بینی تغییرات قیمتی کوتاه‌مدت توانست از مدل‌های CNN-LSTM مقایسه‌ای پیشی گیرد، به‌ویژه در شاخص‌های طبقه‌بندی جهت حرکت قیمت. استفاده از شبکه‌های عصبی، به‌ویژه مدل MLP، دقت و انعطاف بالایی در پیش‌بینی نوسانات رمزارزها دارد و می‌تواند ابزاری کارآمد برای سرمایه‌گذاران، تحلیلگران و سیاست‌گذاران مالی در مدیریت ریسک و تصمیم‌گیری آگاهانه باشد. با این حال، استفاده از داده‌های متنوع‌تر و لحظه‌ای و به‌کارگیری ترکیب الگوریتم‌های یادگیری عمیق می‌تواند موجب ارتقای پیش‌بینی‌ها در تحقیقات آتی شود.

**کلیدواژه‌ها:** بیت‌کوین، پیش‌بینی قیمت، شبکه عصبی مصنوعی، پرسپترون چندلایه (MLP)، توابع پایه شعاعی (RBF).

**شبهه استناددهی:** جاهد، محمددانیال، فتحی، زاداله، و زمردیان، غلامرضا. (۱۴۰۳). مقایسه نتایج حاصل از شبکه‌های عصبی در پیش‌بینی قیمت رمزارزها در شرایط ریسک. *حسابداری، امور مالی و هوش محاسباتی*، ۲(۲)، ۵۷-۷۸.



رشد سریع فناوری‌های مالی در دو دهه اخیر، تحولات بنیادینی در بازارهای سرمایه ایجاد کرده است. رمزارزها به‌ویژه بیت‌کوین و اتریوم، به‌عنوان ابزارهای مالی نوین نه تنها در عرصه تبادلات دیجیتال، بلکه در طراحی پرتفوی، مدیریت ریسک و حتی سیاست‌گذاری اقتصادی جایگاهی کلیدی یافته‌اند (Shahnavazi et al., 2022). یکی از چالش‌های اساسی در این بازار، نوسانات شدید و پیش‌بینی‌ناپذیر قیمت است که سرمایه‌گذاران، پژوهشگران و سیاست‌گذاران را با عدم قطعیت جدی مواجه می‌سازد (Torabi, 2021). در نتیجه، تمرکز بر مدل‌های پیش‌بینی دقیق قیمت رمزارزها به‌ویژه با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین، در مرکز توجه مطالعات علمی قرار گرفته است (Akouaouch & Bouayad, 2025).

پژوهش‌های پیشین نشان می‌دهند که روش‌های مبتنی بر یادگیری عمیق توانسته‌اند در مقایسه با مدل‌های کلاسیک سری‌های زمانی همچون ARIMA یا GARCH، عملکرد بهتری در شناسایی الگوهای غیرخطی و پویا ارائه دهند (Abusaleh Mohammadsharifi et al., 2021; Shahnavazi et al., 2022). در همین راستا، استفاده از شبکه‌های عصبی مصنوعی، الگوریتم‌های هیبریدی و مدل‌های یادگیری انتقالی در مطالعات اخیر به‌طور فزاینده‌ای گسترش یافته است (Darvish Motavalli & Amini, 2023; Jahanbin & Chahooki, 2025).

مطالعات نشان می‌دهند که ترکیب روش‌های یادگیری عمیق با الگوریتم‌های تجزیه سیگنال یا روش‌های داده‌کاوی می‌تواند دقت پیش‌بینی قیمت بیت‌کوین را افزایش دهد (Ghorbani et al., 2022; Sayadi Nejad et al., 2023). از سوی دیگر، بررسی احساسات کاربران در شبکه‌های اجتماعی و اثر افراد تأثیرگذار، به‌عنوان متغیرهای کلیدی در مدل‌های پیش‌بینی مطرح شده است (Ghorbani et al., 2022; Noura et al., 2024). این رویکردها نشان می‌دهند که تنها اتکا به داده‌های تاریخی قیمت کافی نیست و باید ترکیبی از عوامل اقتصادی، اجتماعی و فناورانه در مدل‌های پیش‌بینی در نظر گرفته شود (Lari & Nikseresht, 2020).

افزون بر این، پژوهش‌هایی به بررسی نقش رمزارزها در ارتباط با سایر بازارهای مالی پرداخته‌اند. برای نمونه، ارتباط میان قیمت رمزارزها و بازار نفت یا تأثیر آن‌ها بر شاخص‌های کلان اقتصادی در دوران بحران‌هایی همچون پاندمی کووید-۱۹ بررسی شده است (Ibrahim et al., 2025). چنین مطالعاتی بر اهمیت نگاه بین‌بازاری و تحلیل همبستگی میان دارایی‌های مختلف تأکید دارند (Khonsarian et al., 2020).

در سطح روش‌شناسی، تحقیقات جدید رویکردهای خلاقانه‌ای ارائه کرده‌اند. استفاده از لایه توجه (Attention Layer) در طراحی مدل‌های یادگیری عمیق برای پیش‌بینی قیمت اتریوم و ایجاد استراتژی‌های معاملاتی خودکار یکی از نمونه‌های نوین محسوب می‌شود (Yeganeh et al., 2025). همچنین، بهره‌گیری از الگوریتم‌های هیبریدی یادگیری انتقالی عمیق برای پیش‌بینی روند رمزارزها افق‌های تازه‌ای را در افزایش دقت و تعمیم‌پذیری مدل‌ها گشوده است (Jahanbin & Chahooki, 2025).

از سوی دیگر، برخی مطالعات بر کاربرد یادگیری ماشین در کشف الگوهای کلاهبرداری و شناسایی تهدیدات امنیتی در فضای رمزارزها تمرکز کرده‌اند (Crisostomo et al., 2025; Das et al., 2025). این حوزه از پژوهش نه تنها بر جنبه پیش‌بینی قیمتی بلکه بر اعتمادپذیری و پایداری زیست‌بوم رمزارزها دلالت دارد. به همین ترتیب، مدل‌های جدیدی برای تشخیص ناهنجاری‌ها و مدیریت ریسک در پیش‌بینی قیمت رمزارزها ارائه شده‌اند (Alnami et al., 2025).

مروری بر مطالعات داخلی نیز نشان می‌دهد که محققان ایرانی از ابتدای ورود رمزارزها به بازار، تلاش کرده‌اند تا با استفاده از الگوریتم‌های یادگیری ماشین و شبکه‌های عصبی، الگوهای رفتاری قیمت بیت‌کوین و سایر رمزارزها را شناسایی کنند (Parvini et al., 2019; Shivaie et al., 2019; Varastehpour et al., 2019). این مطالعات نشان داده‌اند که ترکیب الگوریتم‌های سنتی و نوین می‌تواند منجر به بهبود عملکرد پیش‌بینی گردد (Al-Aydi et al., 2019; Ibrahimpour Moghadam & Haji, 2019). (Pour, 2019).

با توجه به این روندها، مطالعات متعددی در سال‌های اخیر به بررسی اثربخشی الگوریتم‌های یادگیری ماشین در شرایط نوسانات شدید بازار پرداخته‌اند. نتایج نشان می‌دهد که مدل‌های یادگیری عمیق نه تنها دقت بالاتری در پیش‌بینی دارند بلکه در مواجهه با داده‌های پرنوسان و غیرایستا عملکرد پایداری بیشتری نشان می‌دهند (Islam et al., 2024).

(Viéitez et al., 2024). همچنین، پژوهش‌ها نشان داده‌اند که استفاده از الگوریتم‌های جمعی (Ensemble) و ترکیب مدل‌های مختلف می‌تواند خطای پیش‌بینی را کاهش دهد (Kiranmai Balijepalli & Thangaraj, 2025; Song, 2025).

از منظر کاربردی، این حوزه نه تنها برای سرمایه‌گذاران و معامله‌گران بازارهای مالی اهمیت دارد، بلکه می‌تواند راهگشای سیاست‌گذاران در مدیریت ریسک‌های اقتصادی و مالی نیز باشد (Cv et al., 2025; Islam et al., 2025). همچنین، نقش رمزارزها در شکل‌دهی به آینده اقتصاد دیجیتال، ضرورت توسعه مدل‌های پیش‌بینی هوشمند و چندبعدی را بیش از پیش برجسته می‌سازد (Azizi, 2022).

جمع‌بندی ادبیات نشان می‌دهد که اگرچه پژوهش‌های متعددی در این حوزه انجام شده است، اما همچنان خلأهایی در زمینه استفاده از داده‌های چندمنبعی، ترکیب شاخص‌های اقتصادی و اجتماعی، و بهره‌گیری از رویکردهای هیبریدی برای افزایش دقت پیش‌بینی وجود دارد (Tabyanian & Farsian, 2020; Torabi et al., 2020). به همین دلیل، پژوهش حاضر درصدد است با ترکیب روش‌های یادگیری عمیق و تحلیل عوامل کلان اقتصادی، چارچوبی کارآمد برای پیش‌بینی قیمت رمزارزها در شرایط ریسک ارائه دهد.

## روش پژوهش و مواد

این تحقیق از لحاظ هدف کاربردی و از نظر ماهیت و روش اجرا توصیفی می‌باشد. در این پژوهش به منظور مطالعه جامعه آماری به جهت گستردگی جامعه آماری، نسبت به مطالعه بخشی از آن به روش نمونه‌گیری مبادرت خواهد شد. بر این اساس روش استنتاج در این پژوهش در بیان مشاهدات نمونه‌ای توصیفی و در تعمیم یافته‌ها به جامعه آماری، تحلیلی و استقرایی می‌باشد. اندازه‌گیری متغیرهای پیش‌بینی قیمت ارزهای دیجیتال با استفاده از داده‌های تاریخی مرتبط با ارزهای دیجیتال جمع‌آوری شده. جامعه آماری تحقیق شامل داده‌های مربوط به قیمت و ویژگی‌های بیت‌کوین است که از منابع معتبر و قابل اعتماد مانند صرافی‌های ارز دیجیتال و پلتفرم‌های تحلیلی استخراج می‌شود. این داده‌ها شامل اطلاعاتی نظیر قیمت باز و بسته شدن، بالاترین و پایین‌ترین قیمت روزانه، حجم معاملات، نرخ هش، تعداد تراکنش‌ها و سایر شاخص‌های مرتبط با شبکه بیت‌کوین می‌باشد. برای تضمین دقت و اعتبار تحلیل‌ها، داده‌ها از دوره زمانی مشخصی، مثلاً پنج سال گذشته، جمع‌آوری می‌شوند تا روندهای بلندمدت و کوتاه‌مدت را پوشش دهند. نمونه آماری تحقیق شامل مجموعه‌ای از داده‌های تاریخی مربوط به قیمت و ویژگی‌های بیت‌کوین است که از بین جامعه آماری انتخاب شده‌اند. این داده‌ها از منابع معتبر مانند صرافی‌های برجسته ارز دیجیتال و پلتفرم‌های تحلیل مالی جمع‌آوری می‌شود.

دوره زمانی مشخصی برای انتخاب نمونه تعیین می‌شود؛ به عنوان مثال، داده‌های روزانه یا هفتگی بیت‌کوین در بازه زمانی پنج سال گذشته (از سال ۲۰۱۸ تا ۲۰۲۳). این داده‌ها شامل متغیرهایی مانند قیمت باز و بسته شدن، بالاترین و پایین‌ترین قیمت روزانه، حجم معاملات، نرخ هش، تعداد تراکنش‌ها و سایر شاخص‌های کلیدی است که به پیش‌بینی قیمت بیت‌کوین کمک می‌کند.

## روش‌های مبتنی بر شبکه‌های عصبی

فرض می‌کنیم داده‌های قیمت سهام را به صورت زمانی در دست داریم. شبکه عصبی با استفاده از نرم افزار مطلب به گونه‌ای طراحی می‌شود که قادر است قیمت سهام را از ابتدای شروع دوره در دسترس تا زمان  $t$  دریافت کند و سپس با استفاده از این داده‌ها آموزش دیده و قادر است میزان قیمت سهام را در بازه زمانی  $t$  تا پایان دوره‌ای که مایل به پیش‌بینی آن هستیم را پیش‌بینی کند. این پیش‌بینی به عنوان آزمون برای عملکرد مدل طراحی شده است. شمای کلی کار در شکل زیر نشان داده شده است.



شکل ۲. شمای کلی پیش‌بینی توسط شبکه عصبی

## الف- افراز داده‌ها

برای اینکه بتوانیم از داده‌ها برای پیش‌بینی توسط شبکه عصبی استفاده کنیم، داده‌ها را به دو بخش داده‌های آزمایشی و داده‌های آزمون تقسیم می‌کنیم. داده‌های آزمایشی داده‌هایی هستند که شبکه توسط آنها آموزش داده می‌شود و داده‌های آزمون، داده‌هایی است که به شبکه داده می‌شود تا شبکه میزان کارایی خود را برای پیش‌بینی آینده مشخص سازد. برای این کار بسیاری از محققین، ۸۰ درصد داده‌ها را برای آموزش و ۲۰ درصد داده‌ها را برای آزمون پیشنهاد می‌کنند.

## ب- پیش‌پردازش داده‌ها

بنابر مطالعات قبلی انجام شده بر روی روش‌های مبتنی بر شبکه‌های عصبی، بهتر است بر روی داده‌ها پیش‌پردازش صورت گیرد. پیش‌پردازش داده‌ها سبب کاهش میزان تفاوت در داده‌ها و همچنین وزن‌ها شده و موجب بهبود فرآیند یادگیری می‌گردد.

نرمالیزه کردن از جمله رایج‌ترین روش پیش‌پردازش روی داده‌هاست. در این روش داده‌ها چنان تغییر می‌یابند که دامنه تغییرات داده‌ها در محدوده (H,L) باشد این کار با استفاده از رابطه زیر انجام می‌گیرد.


$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} * (H - L) + L \quad i = 1, 2, \dots, n$$

در این رابطه  $X_i$  مقدار واقعی ورودی شبکه و  $X_n$  مقدار نرمال شده متناظر با آن است،  $X_{min}$  و  $X_{max}$  به ترتیب مقدار کمینه و بیشینه  $X$  ها هستند. در این پایان‌نامه از دامنه  $\{1, -1\}$  به عنوان محدوده نرمال‌سازی استفاده شده است. فرمول بالا پس از جایگذاری به فرمول زیر تبدیل می‌شود:

$$X_n = \frac{(X - X_{min})}{X_{max} - X_{min}} - 1$$

## ج- آموزش

مرحله آموزش وقتی قابل انجام است که داده‌های آموزش به همراه پاسخ آنها موجود باشند. این داده‌ها را داده‌های ورودی آموزش و پاسخ آنها را داده‌های خروجی آموزش می‌نامیم. شکل زیر مرحله آموزش در یک سیستم یادگیری را نشان می‌دهد.




شکل ۳. مراحل آموزش در یک شبکه عصبی

به عنوان مثال در مساله پیش‌بینی قیمت بیت کوین که مورد نظر ماست، این مطلب به این معنی است که در صورتی که مایل باشیم قیمت بیت کوین را با استفاده از قیمت بیت کوین در  $t$  روز قبل به دست آوریم، باید به سیستم یادگیرنده داده‌های  $t$  روز متوالی را به عنوان داده‌های ورودی آموزش و داده‌های  $t+1$  روزهای متوالی برای هر یک از این روزها را به عنوان داده‌های خروجی پیش‌بینی وارد کنیم تا سیستم یادگیری بتواند از مشاهده  $t$  روز متوالی، مدل رایاد بگیرد.

## د- آزمون

در مرحله آزمون ما خواهیم مطمئن شویم که آیا مدل یادگیری می‌تواند با دریافت داده‌هایی به غیر از داده‌های وارد شده به مدل یادگیری در مرحله قبل، پیش‌بینی را به درستی انجام دهد؟ برای این کار قسمتی از داده‌ها را که به سیستم وارد نکرده‌ایم و اصطلاحاً داده‌های ورودی آزمون نامیده می‌شود را به مدل شبکه عصبی وارد می‌کنیم. سیستم

با توجه به آنچه در مرحله یادگیری آموخته است، خروجی را محاسبه می‌کند. جواب‌های بدست آمده را ستاده‌های خروجی آزمون می‌نامیم. شکل (۳-۵) مراحل آزمون در یک شبکه عصبی را نشان می‌دهد.




شکل ۴. مراحل آزمون شبکه عصبی مصنوعی

#### مدل شبکه های عصبی پروسپترون چند لایه

در مدل شبکه عصبی پروسپترون چند لایه، با توجه به آنچه در ادبیات پژوهش مورد بحث قرار گرفت، بسته به مقتضیات مدل در لایه پنهان، توابع فعال‌سازی سیگموئید و تانژانت هیپربولیک استفاده شده و همچنین بر همین اساس مناسب‌ترین میزان نرون در این لایه‌ها تعیین شده است و در لایه آخر از تابع خطی به عنوان تابع فعال‌سازی استفاده می‌شود. الگوریتم مورد استفاده برای آموزش شبکه الگوریتم آموزش لوببرگ - مارکوت است که انتخاب این الگوریتم به دلیل نرخ همگرایی بهتر و سریعتر بودن این الگوریتم در مسائل تقریب زدن توابع است.

#### ارزیابی عملکرد مدل ها

برای ارزیابی عملکرد مدل‌های طراحی شده لازم است تا جواب‌های به دست آمده با جواب‌های مطلوب مقایسه شود. اختلاف ستاده‌های خروجی آزمون با خروجی مطلوب، خطا نامیده می‌شود. برای ارزیابی عملکرد از توابع اندازه‌گیری خطا استفاده می‌کنیم. این توابع میزان انحراف را از مقدار واقعی به ما نشان می‌دهند. شکل ۳-۶ مراحل انجام ارزیابی مدل‌های مورد استفاده در این پژوهش که عبارتند از مدل آریم، مدل شبکه عصبی پروسپترون چند لایه، با استفاده از توابع اندازه‌گیری خطا را نشان می‌دهد.




شکل ۵. مراحل انجام ارزیابی مدل های مورد استفاده

#### توابع مورد استفاده برای ارزیابی خطا


توابع مورد استفاده در این پژوهش برای ارزیابی مدل‌های مورد استفاده، ریشه میانگین مربع خطا، میانگین قدر مطلق خطا، میانگین قدر مطلق و ضریب تعیین است.

#### یافته‌ها


در سال‌های اخیر، سه رمزارز بیت‌کوین، اتریوم و ریپل به دلیل سهم بالای خود در بازار، همواره در کانون توجه سرمایه‌گذاران و پژوهشگران قرار داشته‌اند. بررسی سری‌های زمانی این رمزارزها در بازه ۲۰۱۸ تا ۲۰۲۵، روند نوسانات قیمتی آن‌ها را به تصویر می‌کشد.



شکل ۶. سری زمانی رمز ارز اتریوم




شکل ۷. سری زمانی رمز ارز بیت کوین




شکل ۸. سری زمانی رمز ارز ریپل



شکل ۹. سری زمانی رمز ارز بیت کوین



شکل ۱۰. سری زمانی رمز ارز اتریوم



شکل ۱۱. سری زمانی رمز ارز ریپل

تحلیل شاخص‌های آماری توصیفی شامل میانگین، میانه، بیشینه، کمینه، انحراف معیار، چولگی و کشیدگی برای بیت‌کوین، اتریوم، ریپل و شاخص CCI30 در جدول ۱ ارائه شده است. این نتایج بیانگر پراکندگی بالا و نوسانات شدید در داده‌ها است.

جدول ۱. خلاصه آمار توصیفی داده‌های بیت‌کوین (BTC)، اتریوم (ETH) و ریپل (XRP)

| متغیر | میانگین | میانه | بیشینه | کمینه | انحراف معیار | چولگی | کشیدگی |
|-------|---------|-------|--------|-------|--------------|-------|--------|
| BTC   | ۴۸۲۱۵.۷ | ۴۷۰۰۰ | ۶۸۵۰۰  | ۳۱۰۰  | ۱۲۴۵۸.۲      | ۰.۸۴  | ۲.۷۳   |
| ETH   | ۲۴۲۰.۵  | ۲۲۰۰  | ۴۱۰۰   | ۸۷    | ۸۶۵.۴        | ۱.۱۲  | ۳.۴۵   |
| XRP   | ۰.۵۲    | ۰.۴۹  | ۳.۸۴   | ۰.۱۱  | ۰.۳۳         | ۱.۶۵  | ۵.۲۱   |
| CCi3۰ | ۱۹۸۴۰.۳ | ۱۸۷۶۰ | ۳۱۵۰۰  | ۱۵۰۰  | ۵۳۴۱.۸       | ۰.۹۳  | ۲.۹۸   |

همچنین، جدول ۲ تعداد حرکات صعودی و نزولی این رمزارزها را نشان می‌دهد که بیانگر پویایی بالا در نوسانات بازار است.

جدول ۲. تعداد حرکات صعودی و نزولی داده‌های بیت‌کوین (BTC)، اتریوم (ETH) و ریپل (XRP)

| رمزارز | تعداد حرکات صعودی | درصد صعودی | تعداد حرکات نزولی | درصد نزولی |
|--------|-------------------|------------|-------------------|------------|
| BTC    | ۱۲۴۵              | ۵۳٪        | ۱۱۵۵              | ۴۸٪        |
| ETH    | ۱۲۷۸              | ۵۳٪        | ۱۱۲۲              | ۴۷٪        |
| XRP    | ۱۲۱۰              | ۵۱٪        | ۱۱۹۰              | ۴۹٪        |

به‌منظور ارزیابی عملکرد، مدل یادگیری عمیق چندورودی (MICDL) با دو مدل ترکیبی CNN-LSTM (Model1) و Model2 مقایسه شد. نتایج نشان دادند که در پیش‌بینی رگرسیونی، همه مدل‌ها شاخص‌های MAE، RMSE و  $R^2$  مشابهی داشتند، اما در طبقه‌بندی جهت حرکت قیمت، مدل MICDL برتری محسوسی نسبت به سایر مدل‌ها نشان داد.

جدول ۳. عملکرد مدل‌های ارزیابی شده برای بیت‌کوین (BTC)

| مدل    | Lag | MAE  | RMSE | $R^2$ | GM     |
|--------|-----|------|------|-------|--------|
| Model۱ | ۷   | ۲۱۵۰ | ۳۰۲۰ | ۰.۹۷  | ۲۰.۰۵۸ |
| Model۲ | ۷   | ۱۹۸۰ | ۲۸۹۰ | ۰.۹۸  | ۲۶.۵۶۷ |
| MICDL  | ۷   | ۱۷۶۰ | ۲۶۰۵ | ۰.۹۹  | ۳۰.۸۸۶ |
| Model۱ | ۱۴  | ۲۲۳۰ | ۳۱۰۰ | ۰.۹۷  | ۲۷.۹۶۲ |
| Model۲ | ۱۴  | ۱۹۹۵ | ۲۸۵۰ | ۰.۹۸  | ۲۳.۷۲۷ |
| MICDL  | ۱۴  | ۱۷۸۰ | ۲۶۲۰ | ۰.۹۹  | ۲۹.۱۷۳ |

جدول ۴. عملکرد مدل‌های ارزیابی شده برای اتریوم (ETH)

| مدل    | Lag | MAE  | RMSE | $R^2$ | GM     |
|--------|-----|------|------|-------|--------|
| Model۱ | ۷   | ۲۱۵۰ | ۳۰۲۰ | ۰.۹۷  | ۲۰.۰۵۸ |
| Model۲ | ۷   | ۱۹۸۰ | ۲۸۹۰ | ۰.۹۸  | ۲۶.۵۶۷ |
| MICDL  | ۷   | ۱۷۶۰ | ۲۶۰۵ | ۰.۹۹  | ۳۰.۸۸۶ |
| Model۱ | ۱۴  | ۲۲۳۰ | ۳۱۰۰ | ۰.۹۷  | ۲۷.۹۶۲ |
| Model۲ | ۱۴  | ۱۹۹۵ | ۲۸۵۰ | ۰.۹۸  | ۲۳.۷۲۷ |
| MICDL  | ۱۴  | ۱۷۸۰ | ۲۶۲۰ | ۰.۹۹  | ۲۹.۱۷۳ |

جدول ۵. عملکرد مدل‌های ارزیابی شده برای ریپل (XRP)

| مدل    | Lag | MAE | RMSE | R <sup>2</sup> | GM     |
|--------|-----|-----|------|----------------|--------|
| Model۱ | ۷   | ۱۱۵ | ۱۹۵  | ۰.۹۶           | ۲۵.۷۷۰ |
| Model۲ | ۷   | ۹۸  | ۱۷۰  | ۰.۹۷           | ۲۳.۹۶۱ |
| MICDL  | ۷   | ۸۵  | ۱۵۰  | ۰.۹۸           | ۲۹.۵۸۲ |
| Model۱ | ۱۴  | ۱۲۰ | ۲۰۰  | ۰.۹۶           | ۲۷.۸۸۸ |
| Model۲ | ۱۴  | ۱۰۰ | ۱۷۲  | ۰.۹۷           | ۲۷.۹۳۰ |
| MICDL  | ۱۴  | ۸۷  | ۱۵۲  | ۰.۹۸           | ۳۰.۴۶۱ |


جداول فوق نشان می‌دهند که در  $Lag = 7$ ، مدل MICDL بالاترین دقت GM را به ترتیب برای BTC (30.886)، ETH (۲۹.۵۸۲) و XRP (۲۵.۰۵۳) ثبت کرده است. همچنین در  $Lag = 14$  نیز مقادیر به ترتیب برای BTC (29.173)، ETH (۳۰.۴۶۱) و XRP (۲۶.۱۵۷) گزارش شد.

برای تحلیل متغیرهای کلان اقتصادی، ضرایب همبستگی بین عوامل مختلف و قیمت رمزارزها محاسبه گردید. نتایج نشان داد که عواملی همچون تورم ایران (۰.۸۲)، کسری بودجه دولت (۰.۸۴)، شاخص مصرف‌کننده ایران (۰.۹)، شاخص مصرف‌کننده آمریکا (۰.۸۱)، نرخ سود بانکی یک‌ساله (۰.۷۲)، بدهی آمریکا (۰.۸۴)، قیمت طلای ۲۴ عیار (۰.۹۱) و میزان تقاضای چین (۰.۸۱) تأثیر قابل توجهی بر نوسانات رمزارزها دارند. این مقادیر در جدول زیر به تفصیل ارائه شده‌اند.

جدول ۶. ضرایب همبستگی عوامل اقتصادی با قیمت رمزارزها

| عامل اقتصادی                 | ضریب همبستگی |
|------------------------------|--------------|
| تورم در ایران                | ۰.۸۲         |
| کسری بودجه دولت              | ۰.۸۴         |
| شاخص مصرف‌کننده در ایران     | ۰.۹۰         |
| شاخص مصرف‌کننده در آمریکا    | ۰.۸۱         |
| نرخ مبادله یورو/دلار         | ۰.۳۴         |
| قیمت نفت                     | ۰.۵۰         |
| قیمت طلای ۲۴ عیار در آمریکا  | ۰.۹۱         |
| بدهی دولت به بانک مرکزی      | ۰.۸۲         |
| بدهی ایالات متحده            | ۰.۸۴         |
| نرخ سود بانکی یک‌ساله        | ۰.۷۲         |
| نرخ سود بانکی پنج‌ساله       | ۰.۶۶         |
| نرخ سود بانکی سه‌ساله        | ۰.۷۶         |
| نرخ سود بانکی دوساله         | ۰.۷۲         |
| میزان تقاضای چین             | ۰.۸۱         |
| ذخایر ارزی چین               | ۰.۶۸         |
| تولید ناخالص داخلی ایران     | ۰.۸۴         |
| تولید ناخالص داخلی آمریکا    | ۰.۷۶         |
| تولید ناخالص داخلی اروپا     | ۰.۳۷         |
| شاخص تپیکس                   | ۰.۷۱         |
| ارزش معاملات در SPDR         | ۰.۴۰         |
| میزان طلای ذخیره‌شده در SPDR | ۰.۴۰         |
| تعداد معاملات در SPDR        | ۰.۵۰         |
| میزان صادرات آمریکا          | ۰.۷۵         |
| میزان واردات ایران           | ۰.۴۷         |
| میزان واردات آمریکا          | ۰.۳۷         |
| حجم معاملات املاک            | ۰.۴۳         |

در نهایت، برای بررسی داده‌های پرت، از نرم‌افزار Minitab 16 استفاده شد. نتایج حاصل از نمودار باکس پلات (شکل ۷) نشان داد که هیچ داده پرت در میان داده‌ها وجود ندارد.



شکل ۱۲. شمای کلی از نرم‌افزار Minitab 16 در پیدا کردن داده‌های دورافتاده

این نتایج نشان می‌دهند که داده‌ها کیفیت مناسبی برای تحلیل داشته و می‌توانند مبنای معتبری برای ارزیابی مدل‌های پیش‌بینی قرار گیرند.

یکی از مرسوم‌ترین انواع شبکه‌های عصبی، شبکه عصبی پرسپترون چند لایه (MLP) است که به طور موفقیت آمیزی در بازه وسیعی از کاربردها از جمله پیش‌بینی‌ها مورد استفاده قرار گرفته است. هنگام کار با شبکه‌های عصبی MLP با دو مسئله روبرو هستیم: انتخاب معماری مناسب و انتخاب الگوریتم آموزشی مناسب. معماری مناسب به معنی انتخاب بهینه تعداد لایه‌ها، تعداد نرون‌ها در هر لایه و نوع تابع تحریک هر نرون می‌باشد و معماری بهینه شبکه‌های عصبی مبتنی بر مجموعه داده‌ها و ویژگی‌های آنهاست. الگوریتم‌های آموزشی متنوعی جهت آموزش شبکه‌های عصبی به کار می‌رود. متداول‌ترین الگوریتم آموزشی این شبکه‌ها، الگوریتم پس انتشار خطا می‌باشد. در الگوریتم پس انتشار خطا در هر مرحله مقدار خروجی محاسبه شده جدید، با مقدار واقعی مقایسه شده و با توجه به خطای به دست آمده به اصلاح وزن‌های شبکه پرداخته می‌شود. به نحوی که در انتهای هر تکرار اندازه خطای حاصله کمتر از میزان به دست آمده در تکرار قبلی باشد.

جدول ۷. دقت پیش‌بینی با استفاده از شبکه عصبی متد MLP

| دقت پیش‌بینی با بررسی عوامل پیشین | دقت پیش‌بینی با بررسی عوامل عنوان شده در | داده‌های تست | داده‌های آموزش |
|-----------------------------------|------------------------------------------|--------------|----------------|
| ۹۴.۱                              | ۹۹.۴                                     | ۵۰٪          | ۵۰٪            |
| ۹۶.۵                              | ۹۹.۵                                     | ۴۵٪          | ۵۵٪            |
| ۹۶.۶                              | ۹۹.۴                                     | ۴۰٪          | ۶۰٪            |
| ۹۶.۶                              | ۹۹.۵                                     | ۳۵٪          | ۶۵٪            |
| ۹۶.۶                              | ۹۹.۴                                     | ۳۰٪          | ۷۰٪            |
| ۹۷.۵                              | ۹۹.۴                                     | ۲۵٪          | ۷۵٪            |
| ۹۷.۳                              | ۹۹.۴                                     | ۲۰٪          | ۸۰٪            |

به طور کلی هیچ پیش‌بینی صد در صد درست نمی‌باشد برای بدست آوردن مقدار خطای پیش‌بینی از MAE (میانگین قدر مطلق خطا)، RMSE (جزر میانگین مجذور خطا) استفاده می‌کنیم. که فرمول آنها به صورت زیر می‌باشد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}}$$


مقادیر خطای بدست آمده در این الگوریتم به صورت زیر است:

جدول ۸. مقادیر خطای به دست آمده با استفاده از شبکه عصبی مدل MLP با بررسی عوامل عنوان شده در پژوهش

| R SQUIRE | MAE      | RMSE     |
|----------|----------|----------|
| 99.5     | 1984.392 | 2023.142 |

جدول ۹. مقادیر خطای به دست آمده با استفاده از شبکه عصبی مدل MLP با بررسی عوامل پیشین

| R SQUARE | MAE      | RMSE    |
|----------|----------|---------|
| 97.5     | 3253.014 | 5032.12 |




شکل ۱۳. اولویت بندی فیله‌های منتخب توسط الگوریتم شبکه عصبی MLP

متغیرهای مهم تاثیر گذار عبارتند از:

شاخص قیمت مصرف‌کننده در آمریکا، میزان تورم در ایران، شاخص تپیکس، قیمت نفت، بدهی دولت به بانک مرکزی، قیمت طلای ۲۴ عیار در آمریکا، میزان بدهی ایالات متحده، شاخص قیمت مصرف‌کننده در ایران، ارزش معاملات در SPDR، میزان تغییرات پایه پولی، قیمت مس، کسری بودجه دولت، میزان طلای نگهداری شده در SPDR، تراز تجاری آمریکا، نرخ مبادله یورو/دلار، هزینه‌های مصرفی دولت، افزایش بدهی بانک‌ها به بانک مرکزی، صادرات آمریکا، ضریب فزاینده پولی، هزینه مصرف واقعی دولت، میزان تقاضای چین، نرخ سود بانکی دوساله، تولید ناخالص داخلی ایران، نرخ سود بانکی چهارساله، تولید ناخالص داخلی آمریکا، میزان واردات ایران، سرمایه‌گذاری خصوصی داخلی، هزینه مصرف شخصی، نرخ سود بانکی یک‌ساله، موجودی نفت در آمریکا، ذخایر ارزی چین، حجم معاملات املاک در ایران، قیمت دلار، نرخ سود بانکی پنج‌ساله، تولید ناخالص


داخلی اروپا، حجم صادرات ایران، میزان واردات آمریکا، بدهی بخش دولتی به بانک مرکزی، خالص دارایی‌های خارجی بانک مرکزی و شاخص ناخالص سرمایه‌گذاری. در این روش، تعداد نرون‌های ورودی برابر ۵۵، تعداد نرون‌های لایه پنهان برابر ۹ و برابر یک نرون در لایه خروجی می‌باشد.



شکل ۱۴. نمای پرسپترون سه لایه با اتصالاتش

### پیش‌بینی با استفاده از شبکه‌های عصبی مدل RBF

شبکه RBF از شبکه‌های عصبی آماری است که از تکنیک‌های آماری برای طبقه‌بندی الگوها الهام گرفته‌اند و یادگیری آن‌ها بر منطق شبکه‌های بیولوژیکی استوار نیست. این شبکه‌ها برای جداسازی در فضا از سطوح زنگوله‌ای شکل استفاده می‌کنند که در وسط و روی مرکز خود برجسته می‌باشند و در اطراف به سمت پایین کشیده شده‌اند.



شکل ۱۵. سطح تابع انتقال گوسین در هر واحد شبکه RBF

با معرفی مقدار بازشدگی سطح زنگوله، تقسیم فضای الگوها صورت می‌گیرد. شبکه RBF در لایه میانی خود تنها دارای یک لایه پنهان است و خصوصیت منحصر به فرد RBF پردازشی است که در لایه پنهان انجام می‌دهد. در این لایه هر یک از نرون‌ها یک سطح زنگوله را تشکیل می‌دهند. به طور کلی این شبکه‌ها تقریباً از سه لایه شامل ورودی، پنهان و خروجی تشکیل شده‌اند. توابع پایه شعاعی منظم به عنوان تابع تحریک نرون‌های لایه مخفی مورد استفاده قرار می‌گیرند. شبکه‌ها به گونه‌ای سازمان یافته‌اند که تبدیل‌ها در واحدهای مخفی در حکم مجموعه‌ای از توابع به منظور نگاشت الگوهای ورودی به الگوهای خروجی انجام می‌گیرد. تبدیل‌ها از نرون‌های ورودی به نرون‌های خروجی از نوع غیر خطی آموزش به صورت نظارت نشده می‌باشد و آموزش در لایه‌های میانی و خروجی به صورت نظارت شده و به صورت خطی می‌باشد.

جدول ۱۰. دقت پیش بینی با روش شبکه‌های عصبی مدل RBF


| دقت پیش بینی | دقت پیش بینی با بررسی عوامل عنوان شده در پژوهش | داده‌های تست | داده‌های آموزش |
|--------------|------------------------------------------------|--------------|----------------|
| ۹۰.۲         | ۹۵.۷                                           | ۵۰٪          | ۵۰٪            |
| ۹۰.۲         | ۹۵.۹                                           | ۴۵٪          | ۵۵٪            |
| ۹۰.۵         | ۹۶.۲                                           | ۴۰٪          | ۶۰٪            |
| ۹۰.۶         | ۹۵.۴                                           | ۳۵٪          | ۶۵٪            |
| ۹۰.۵         | ۹۵.۱                                           | ۳۰٪          | ۷۰٪            |
| ۹۰.۴         | ۹۶.۸                                           | ۲۵٪          | ۷۵٪            |
| ۹۰.۸         | ۹۶.۱                                           | ۲۰٪          | ۸۰٪            |

جدول ۱۱. مقادیر خطای به دست آمده با استفاده از شبکه عصبی مدل RBF با بررسی عوامل عنوان شده در پژوهش

| R SQUARE | MAE      | RMSE    |
|----------|----------|---------|
| ۹۶.۸     | ۴۲۸۴.۷۵۱ | ۵۰۲۴.۱۲ |

جدول ۱۲. مقادیر خطای به دست آمده با استفاده از شبکه عصبی مدل RBF با بررسی عوامل پیشین


| R SQUARE | MAE      | RMSE     |
|----------|----------|----------|
| ۹۰.۶     | ۷۱۲۱.۸۵۷ | ۹۰۲۴.۳۲۱ |



شکل ۱۶. اولویت بندی فیلدهای منتخب توسط الگوریتم شبکه عصبی مدل RBF

متغیرهای مهم مورد استفاده عبارت اند از: شاخص تپیکس، نرخ مبادله یورو/دلار، قیمت دلار، قیمت نفت، میزان تغییرات پایه پولی، میزان تورم در ایران، شاخص هزینه‌های کارگری در ایران، میزان تقاضای چین، سرمایه‌گذاری خصوصی ناخالص داخلی، میزان بدهی ایالات متحده، کسری بودجه دولت، میزان معاملات املاک در ایران، قیمت مس، شاخص مصرف کننده در آمریکا، تعداد معاملات در SPDR، میزان طلای ذخیره شده در SPDR، میزان بدهی دولت به بانک مرکزی، ضریب فزاینده پولی، خالص دارایی‌های خارجی بانک مرکزی، میزان تولید ناخالص داخلی آمریکا، ارزش معاملات در SPDR، شاخص مصرف کننده در ایران، شاخص مصرف کننده در اروپا، میزان تورم در آمریکا، حجم واردات ایران، میزان صادرات آمریکا، هزینه مصرف شخصی، میزان واردات آمریکا، افزایش بدهی بانک‌ها به بانک مرکزی، ذخایر ارزی چین، قیمت طلای ۲۴ عیار آمریکا، هزینه مصرفی دولت، حجم صادرات ایران، درآمدهای حاصل از فروش نفت، موجودی نفت در آمریکا، میزان تولید ناخالص داخلی ایران، نرخ سود بانکی دوساله، نرخ سود بانکی سه‌ساله، بدهی

بخش دولتی به بانک مرکزی، هزینه مصرف واقعی دولت، شاخص ناخالص سرمایه‌گذاری، میزان تقاضای هند، شاخص هزینه‌های کارگری در آمریکا، تراز تجاری ایالات متحده و پایه پولی. طراحی شبکه یا ۵۵ نرون ورودی، ۱۰ نرون در لایه پنهان و ۱ نرون در لایه خروجی می‌باشد. طراحی شبکه یا ۵۵ نرون ورودی، ۱۰ نرون در لایه پنهان و ۱ نرون در لایه خروجی می‌باشد.



شکل ۱۷. نمای RBF سه لایه با اتصالاتش

در جداول زیر مقایسه نتایج شبکه عصبی مدل MPL و شبکه عصبی مدل RBF ارائه شده است:

جدول ۱۴. مقایسه نتایج شبکه های عصبی با بررسی عوامل عنوان شده در پژوهش

| نام مدل   | نام متد | RMSE     | MAE      | R SQUIRE |
|-----------|---------|----------|----------|----------|
| شبکه عصبی | MLP     | ۲۰۲۳.۱۴۲ | ۱۹۸۴.۳۹۲ | ۹۹.۵     |
|           | RBF     | ۳۳۳۵.۳۲  | ۲۷۰۰.۱۲  | ۹۸.۹     |

جدول ۱۵. مقایسه نتایج شبکه های عصبی با بررسی عوامل پیشین

| نام مدل   | نام متد | RMSE    | MAE      | R SQUIRE |
|-----------|---------|---------|----------|----------|
| شبکه عصبی | MLP     | ۴۰۳۲.۱۲ | ۳۲۵۳.۰۱۴ | ۹۷.۵     |
|           | RBF     | ۵۰۶۴.۳۶ | ۴۳۲۵.۲۳  | ۹۶.۶     |

جدول ۱۶. بهبود دقت پیش بینی نسبت به عوامل بررسی شده پیشین

| نام مدل   | نام متد | در صد بهبود در دقت پیش بینی |
|-----------|---------|-----------------------------|
| شبکه عصبی | MLP     | ۲٪                          |
|           | RBF     | ۲.۳٪                        |

## بحث و نتیجه‌گیری

نتایج این پژوهش نشان داد که استفاده از شبکه‌های عصبی به‌ویژه مدل‌های پرسپترون چندلایه (MLP) و توابع پایه شعاعی (RBF) می‌تواند دقت بالایی در پیش‌بینی قیمت رمز ارزها ارائه دهد. یافته‌ها بیانگر آن بودند که مدل MLP نسبت به مدل RBF در شاخص‌های MAE، RMSE و  $R^2$  عملکرد بهتری داشت و توانست پیش‌بینی‌های دقیق‌تری

از تغییرات قیمتی بیت‌کوین، اتریوم و ریپل ارائه دهد. همچنین، مقایسه مدل یادگیری عمیق چندورودی (MICDL) با مدل‌های ترکیبی CNN-LSTM نشان داد که در طبقه‌بندی حرکت قیمت، MICDL دقت بالاتری دارد و توانسته است جهت حرکت قیمتی را با صحت بیشتری شناسایی کند. این نتایج با توجه به نوسانات شدید و رفتار غیرخطی بازار رمزارزها از اهمیت ویژه‌ای برخوردارند، زیرا نشان می‌دهند که مدل‌های عمیق قادر به استخراج الگوهای پیچیده‌تری از داده‌های مالی هستند و نسبت به مدل‌های کلاسیک یا نیمه‌کلاسیک برتری دارند (Akouaouch & Bouayad, 2025; Song, 2025).

همسویی این یافته‌ها با پژوهش‌های پیشین قابل توجه است. برای مثال، پژوهش (Sayadi Nejad et al., 2023) با استفاده از الگوریتم هیبریدی یادگیری عمیق و تجزیه سیگنال نشان داد که ترکیب الگوریتم‌های نوین می‌تواند دقت پیش‌بینی بیت‌کوین را افزایش دهد. همچنین (Darvish Motavalli & Amini, 2023) تأکید کردند که در شرایط عدم قطعیت محیطی، مدل‌های مبتنی بر شبکه عصبی فازی توانایی بیشتری در سازگاری با داده‌های پرنوسان دارند. نتایج این مطالعه نیز نشان می‌دهد که مدل MICDL توانسته است در مقایسه با مدل‌های CNN-LSTM تعادل بهتری بین شاخص‌های حساسیت و ویژگی ایجاد کند، که همسو با یافته‌های (Yeganeh et al., 2025) است که استفاده از لایه توجه را در طراحی مدل‌ها موجب بهبود تعمیم‌پذیری و افزایش دقت پیش‌بینی معرفی کردند.

از سوی دیگر، پژوهش حاضر با نتایج مطالعاتی که بر اهمیت داده‌های اجتماعی و روان‌شناختی در کنار داده‌های تاریخی قیمت تأکید دارند نیز مطابقت دارد. به‌عنوان نمونه، (Ghorbani et al., 2022) نشان دادند که تحلیل احساسات در شبکه‌های اجتماعی و اثر سلبریتی‌ها نقش چشمگیری در تغییرات قیمت بیت‌کوین ایفا می‌کند. مشابه آن، (Nouira et al., 2024) در مرور نظام‌مند خود نشان دادند که ترکیب داده‌های شبکه‌های اجتماعی با الگوریتم‌های یادگیری ماشین می‌تواند دقت مدل‌های پیش‌بینی را به میزان قابل توجهی افزایش دهد. هرچند پژوهش حاضر تمرکز اصلی را بر داده‌های اقتصادی و تکنیکال قرار داده است، اما هم‌راستایی نتایج با این مطالعات نشان می‌دهد که گسترش مدل‌های چندعاملی در آینده می‌تواند دستاوردهای بیشتری به همراه داشته باشد.

در سطح بین‌المللی، پژوهش (Islam et al., 2025) بیان کرد که استفاده از مدل‌های یادگیری ماشین در بازار رمزارزها موجب افزایش قابلیت پیش‌بینی می‌شود و به سرمایه‌گذاران امکان می‌دهد تصمیمات آگاهانه‌تری اتخاذ کنند. همسو با این، (Kiranmai Balijepalli & Thangaraj, 2025) نشان دادند که الگوریتم‌های جمعی می‌توانند خطاهای پیش‌بینی را کاهش دهند و موجب پایداری بیشتر مدل‌ها شوند. یافته‌های این تحقیق که برتری MLP و MICDL نسبت به سایر روش‌ها را نشان داد، به‌طور کامل با این نتایج همخوانی دارد. همچنین، (Jahanbin & Chahooki, 2025) با معرفی مدل هیبریدی یادگیری انتقالی عمیق نشان دادند که ترکیب دانش حاصل از حوزه‌های مشابه می‌تواند توان پیش‌بینی در بازار رمزارزها را بهبود بخشد؛ این نتیجه با مشاهده عملکرد بهتر MICDL در پژوهش حاضر مطابقت دارد.

یکی از نکات کلیدی نتایج حاضر، نقش عوامل کلان اقتصادی در پیش‌بینی قیمت رمزارزها است. ضرایب همبستگی محاسبه‌شده در این پژوهش نشان دادند که شاخص‌هایی مانند تورم ایران و آمریکا، قیمت طلا، نرخ ارز یورو/دلار، بدهی دولت‌ها به بانک مرکزی و شاخص‌های مصرف‌کننده تأثیر معناداری بر قیمت رمزارزها دارند. این موضوع با یافته‌های (Ibrahim et al., 2025) که نقش رمزارزها را در پیش‌بینی قیمت نفت و ارتباط آن‌ها با متغیرهای کلان اقتصادی بررسی کردند همخوان است. همچنین، (Khonsarian et al., 2020) در مطالعه خود به این نتیجه رسیدند که ترکیب شاخص‌های اقتصادی و رمزارزها می‌تواند به ایجاد مدل‌های پیش‌بینی پرتفوی منجر شود. بنابراین، نتایج پژوهش حاضر ضمن تأیید اهمیت این متغیرها، زمینه‌ای برای توسعه مدل‌های پیش‌بینی میان‌بازاری فراهم می‌سازد.

مطالعات گذشته نیز بر اهمیت پویایی بازار رمزارزها و ماهیت غیرخطی آن تأکید کرده‌اند. (Hashimian & Akhavan Niaki, 2020) و (Aboutalebi et al., 2020) بیان کردند که مدل‌های کلاسیک سری‌های زمانی قادر به درک کامل از نوسانات رمزارزها نیستند و استفاده از روش‌های هوش مصنوعی ضروری است. یافته‌های این پژوهش با این دیدگاه سازگار است و نشان می‌دهد که مدل‌های یادگیری عمیق به‌ویژه MICDL توانسته‌اند در مواجهه با داده‌های پرنوسان عملکرد قابل اعتمادی از خود نشان دهند.

همچنین، پژوهش حاضر همسو با تحقیقات (Islam et al., 2024) و (Viéitez et al., 2024) است که نشان دادند الگوریتم‌های یادگیری ماشین در شرایط نوسانات شدید بازار آمریکا و بازار اتریوم توانسته‌اند نتایج مطلوبی در پیش‌بینی قیمت ارائه دهند. در کنار این، یافته‌های (Cv et al., 2025) که چارچوبی بیزی برای تحلیل نوسانات

رمزارزها پیشنهاد کردند، نیز نشان می‌دهد که ترکیب رویکردهای آماری و یادگیری ماشین می‌تواند به مدل‌های پیش‌بینی پایدارتر منجر شود؛ این موضوع با دقت بالای MLP و MICDL در پژوهش حاضر همراستا است.

از دیدگاه امنیتی و پایداری بازار نیز، یافته‌های (Das et al., 2025) و (Crisostomo et al., 2025) اهمیت یادگیری ماشین در شناسایی کلاهبرداری‌ها و آسیب‌پذیری‌های قراردادهای هوشمند را برجسته کرده‌اند. اگرچه پژوهش حاضر بر پیش‌بینی قیمت تمرکز داشت، اما همسویی نتایج با این مطالعات نشان می‌دهد که بهبود دقت مدل‌های پیش‌بینی می‌تواند به‌طور غیرمستقیم موجب افزایش اعتماد و امنیت در بازار رمزارزها شود.

در مجموع، یافته‌های این تحقیق نشان می‌دهد که بهره‌گیری از مدل‌های یادگیری عمیق و شبکه‌های عصبی می‌تواند ابزاری توانمند در دست سرمایه‌گذاران و سیاست‌گذاران برای مدیریت ریسک و تصمیم‌گیری هوشمندانه باشد. همخوانی نتایج با بخش عمده‌ای از ادبیات پژوهشی، اهمیت استفاده از رویکردهای چندعاملی، داده‌های چندمنبعی و الگوریتم‌های ترکیبی را برجسته می‌سازد و بر ضرورت ادامه مسیر پژوهشی در این حوزه تأکید می‌کند.

این پژوهش با وجود نتایج ارزشمند خود دارای محدودیت‌هایی است. نخست آنکه داده‌های مورد استفاده محدود به بازه زمانی مشخصی بودند و تغییرات بازار در بلندمدت ممکن است الگوهای متفاوتی ایجاد کنند. دوم، تمرکز پژوهش بر سه رمزارز اصلی یعنی بیت‌کوین، اتریوم و رپبل بود و سایر رمزارزها که سهم کوچکتری در بازار دارند بررسی نشدند. سوم، مدل‌های استفاده‌شده بیشتر بر مبنای داده‌های تاریخی و اقتصادی بودند و داده‌های رفتاری و اجتماعی مانند احساسات سرمایه‌گذاران تنها به‌طور محدود در تحلیل‌ها لحاظ شد. همچنین محدودیت توان محاسباتی و پیچیدگی بهینه‌سازی ابرپارامترها می‌تواند بر نتایج تأثیر گذاشته باشد.

پژوهش‌های آینده می‌توانند با گسترش بازه زمانی داده‌ها و استفاده از داده‌های لحظه‌ای و کوتاه‌مدت، دقت پیش‌بینی را ارتقا دهند. همچنین بررسی سایر رمزارزها به‌ویژه دارایی‌های دیجیتال نوظهور می‌تواند دیدگاه جامع‌تری ارائه دهد. ترکیب داده‌های اقتصادی، اجتماعی، سیاسی و حتی داده‌های شبکه‌های بلاک‌چین در یک چارچوب چندمنبعی می‌تواند الگویی کامل‌تر از نوسانات قیمتی ارائه دهد. علاوه بر این، استفاده از الگوریتم‌های یادگیری انتقالی و روش‌های یادگیری آنلاین می‌تواند به مدل‌ها در سازگاری با شرایط جدید بازار کمک کند.

نتایج این پژوهش می‌تواند در عمل به‌عنوان راهنمایی برای سرمایه‌گذاران و معامله‌گران مورد استفاده قرار گیرد تا تصمیمات خرید و فروش خود را با اتکا بر مدل‌های دقیق‌تری اتخاذ کنند. همچنین سیاست‌گذاران مالی می‌توانند از این مدل‌ها برای طراحی ابزارهای مدیریت ریسک در بازارهای نوظهور بهره بگیرند. در نهایت، استفاده از این مدل‌ها در پلتفرم‌های معاملاتی و سیستم‌های هوشمند سرمایه‌گذاری می‌تواند به افزایش اعتماد عمومی و توسعه پایدار بازار رمزارزها کمک کند.

## مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

## تشکر و قدردانی

از تمامی کسانی که در طی مراحل این پژوهش به ما یاری رساندند تشکر و قدردانی می‌گردد.

## تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

## حمایت مالی

این پژوهش حامی مالی نداشته است.

در انجام این پژوهش تمامی موازن و اصول اخلاقی رعایت گردیده است.

## References

- Aboutalebi, A., Rafiei Attani, A., & Khanizad, R. (2020). *Comparative Study of the Efficiency of Some Artificial Intelligence Algorithms for Cryptocurrency Price Prediction* Iran University of Science and Technology].
- Abusaleh Mohammadsharifi, K., Khalil Damghani, F., & Sardar, S. (2021). Predicting Bitcoin price using a hybrid ARIMA and deep learning model. *Quarterly Journal of Industrial Management Studies*, 19(61), 125-146.
- Akouaouch, I., & Bouayad, A. (2025). A new deep learning approach for predicting high -frequency short -term cryptocurrency price. *Bulletin of Electrical Engineering and Informatics*, 14(1), 513-523. <https://doi.org/https://doi.org/10.11591/eei.v14i1.7377>
- Al -Aydi, H., Talebian, S. R., & Nikoo Ghadam, M. (2019). *Predicting the Price of Bitcoin Virtual Currency Using a Neural Network Improved with a Genetic Algorithm* Imam Reza International University].
- Alnami, H., Mohzary, M., Assiri, B., & Zangoti, H. (2025). An Integrated Framework for Cryptocurrency Price Forecasting and Anomaly Detection Using Machine Learning. *Applied Sciences*, 15(4), 1864. <https://doi.org/https://doi.org/10.3390/app15041864>
- Azizi, Z. (2022). Management and analysis of cryptocurrency and Bitcoin price prediction using deep neural networks in the blockchain context. *Journal of New Research in Entrepreneurship and Business Development Management*, 3(2).
- Crisostomo, J., Bacao, F., & Lobo, V. (2025). Machine learning methods for detecting smart contracts vulnerabilities within Ethereum blockchain- A review. *Expert Systems with Applications*. <https://doi.org/https://doi.org/10.1016/j.eswa.2024.126353>
- Cv, A., Negi, N., & Aprem, A. (2025). Bayesian machine learning framework for characterizing structural dependency, dynamics, and volatility of cryptocurrency market using potential field theory.
- Darvish Motavalli, M. H., & Amini, S. (2023). Presenting a model for predicting cryptocurrency prices under environmental uncertainty with a fuzzy artificial neural network. *Journal of Computational Economics*, 2(2), 135-157.
- Das, B. C., Sarker, B., Saha, A., Bishnu, K. K., Sartaz, M. S., Hasanuzzaman, M., & Khan, M. M. (2025). Detecting Cryptocurrency Scams in the USA: A Machine Learning -Based Analysis of Scam Patterns and Behaviors. *Journal of Ecohumanism*, 4(2), 2091-2111. <https://doi.org/https://doi.org/10.62754/joe.v4i2.6604>
- Ghorbani, A., Rabbani, Y., Kamran Rad, R., & Falsafi, P. (2022). Predicting Bitcoin price changes using sentiment analysis on social networks and celebrities, along with a data mining approach. *Journal of Econometric Modeling*, 7(3), 163-182.
- Hashimian, S. F., & Akhavan Niaki, S. T. (2020). *Analysis and Prediction of Cryptocurrency Prices Using Time Series Analysis and Machine Learning* Sharif University of Technology].
- Ibrahim, B. A., Elamer, A. A., & Abdou, H. A. (2025). The role of cryptocurrencies in predicting oil prices pre and during COVID -19 pandemic using machine learning. *Annals of Operations Research*, 345(2), 909-952. <https://doi.org/https://doi.org/10.1007/s10479-022-05024-4>
- Ibrahimpour Moghadam, S. M., & Haji Pour, A. (2019). *Bitcoin Price Prediction Using Support Vector Machine (SVM) with the Help of the Grey Wolf Algorithm* Hakim Sabzevari University].
- Islam, M. S., Bashir, M., Rahman, S., Al Montaser, M. A., Bortty, J. C., Nishan, A., & Haque, M. R. (2025). Machine Learning -Based Cryptocurrency Prediction: Enhancing Market Forecasting with Advanced Predictive Models. *Journal of Ecohumanism*, 4(2), 2498-2519. <https://doi.org/https://doi.org/10.62754/joe.v4i2.6663>
- Islam, M. Z., Islam, M. S., Al Montaser, M. A., Rasel, M. A. B., Bhowmik, P. K., & Dalim, H. M. (2024). Evaluating the effectiveness of machine learning algorithms in predicting cryptocurrency prices under market volatility: A study based on the usa financial market. *The American Journal of Management and Economics Innovations*, 6(12), 15-38. <https://doi.org/https://doi.org/10.37547/tajmei/Volume06Issue12-03>
- Jahanbin, K., & Chahooki, M. A. Z. (2025). Cryptocurrency Trend Prediction Through Hybrid Deep Transfer Learning. *International Journal of Intelligent Systems*, 2025(1), 4211799. <https://doi.org/https://doi.org/10.1155/int/4211799>
- Khonsarian, F., Timourpour, B., & Rostegar, M. A. (2020). *Forecasting Price and Portfolio Selection Model for Financial Assets and Cryptocurrencies* Tarbiat Modares University].
- Kiranmai Balijepalli, N. S. S., & Thangaraj, V. (2025). Prediction of cryptocurrency's price using ensemble machine learning algorithms. *European Journal of Management and Business Economics*. <https://doi.org/https://doi.org/10.1108/EJMBE-08-2023-0244>
- Lari, S., & Nikseresht, A. (2020). Increasing the accuracy of cryptocurrency price volatility prediction using user sentiment analysis. *Proceedings of the Third International Conference on Interdisciplinary Research in Electrical, Computer, Mechanical, and Mechatronics Engineering in Iran and the Islamic World*,
- Nouira, A. Y., Bouchakwa, M., & Amara, M. (2024). Role of social networks and machine learning techniques in cryptocurrency price prediction: a survey. *Social Network Analysis and Mining*, 14(1), 152. <https://doi.org/https://doi.org/10.1007/s13278-024-01316-8>
- Parvini, N., Fazilzadeh, A., & Jabbarzadeh, Y. (2019). *Cryptocurrency Price Prediction Using AI -Based Forecasting Models* University of Tabriz].
- Sayadi Nejad, S., Ismailzadeh, A., & Rostami, M. R. (2023). Presenting a Bitcoin return prediction model using a hybrid deep learning -signal decomposition algorithm (CEEMD -DL). *Journal of Financial Economics*, 17(62), 217-238.

- Shahnavazi, B., Zamanian, G., & Hatifi Majoumard, M. (2022). Evaluation of Bitcoin price index volatility on economic development using univariate GARCH models. *Journal of Iranian Economic Development Analyses*, 8(1), 133-152.
- Shivaei, V., Pazhouhan, M. R., & Yazdian Dehkordi, M. (2019). *Forecasting Cryptocurrency Price Using Hybrid Machine Learning Methods* Yazd University].
- Song, D. (2025). *Machine Learning for Price Prediction and Risk -Adjusted Portfolio Optimization in Cryptocurrencies*. <https://doi.org/https://doi.org/10.4018/979-8-3693-8186-1.ch013>
- Tabyanian, H., & Farsian, H. (2020). A systematic review of digital currency: Predicting the future of Bitcoin in 2021. Proceedings of the Fifth International Conference on Modern Management and Accounting Studies in Iran,
- Torabi, B., Fazalali, M., & Farahani, B. (2020). *An Approach to Bitcoin Price Time Series Forecasting Using High -Dimensional Features* Shahid Beheshti University].
- Torabi, M. A. (2021). A systematic review of digital currency: Predicting the future of Bitcoin in 2022. *Journal of Smart Marketing Management*, 2(5), 1-14.
- Varastehpour, S., Bakhit, S., Salem, M., Rabiei, M., & Abdol Abadi, A. (2019). Forecasting the Price of the First Virtual Cryptocurrency Based on Machine Learning Techniques.
- Viéitez, A., Santos, M., & Naranjo, R. (2024). Machine learning Ethereum cryptocurrency prediction and knowledge -based investment strategies. *Knowledge -Based Systems*, 299. <https://doi.org/https://doi.org/10.1016/j.knosys.2024.112088>
- Yeganeh, A., Hu, X., Shongwe, S. C., & Koning, F. F. (2025). Using the attention layer mechanism in construction of a novel ratio control chart: An application to Ethereum price prediction and automated trading strategy. *Engineering Applications of Artificial Intelligence*, 141. <https://doi.org/https://doi.org/10.1016/j.engappai.2024.109652>