

Comparative Analysis of Cryptocurrency Market Behavior in Iran and the United States Using Hybrid Deep Learning Models and Indigenous Trading Strategy Design

1. Alireza Zamanian : PhD Student, Department of Accounting, Bo.C., Islamic Azad University, Borujerd, Iran

2. Mohammad Aslani *: Assistant Professor, Department of Accounting, Tu.C., Islamic Azad University, Tuyserkan, Iran. Email: mohammad.aslani@iau.ac.ir (Corresponding Author)

3. Mahmud Hematfar : Associate Professor, Department of Accounting, Bo.C., Islamic Azad University, Borujerd, Iran

Article history



Received: 16 July 2025

Revised: 30 October 2025

Accepted: 06 November 2025

Published: 23 August 2026

Abstract:

This study aims to develop a spatial–deep learning hybrid model to predict cryptocurrency returns and compare the behavior of the Iranian and U.S. crypto markets in order to design localized trading strategies. This applied–developmental quantitative study analyzed daily data of 32 leading cryptocurrencies from 2018 to 2024. The model architecture integrated: (1) spatial econometrics to capture contagion and network effects; (2) advanced deep learning models such as Graph Neural Networks, CNN–LSTM with attention, and Transformers to detect nonlinear temporal patterns; and (3) deep reinforcement learning for trading strategy optimization. Model performance was assessed using the Diebold–Mariano test and benchmarked against eight comparative models. The proposed spatial–deep hybrid model significantly outperformed both traditional econometric and single-component deep learning models. In the U.S. market, on-chain metrics and technical indicators were dominant predictors of price behavior, while in Iran, macroeconomic factors such as unofficial exchange rates and inflation played a key role. The hybrid model achieved an annualized return of 67.89% with a Sharpe ratio of 1.89 in the U.S. and 51.23% with a Sharpe ratio of 1.48 in Iran. By integrating spatial dependencies and nonlinear temporal dynamics, the model enhanced both predictive accuracy and economic interpretability. The clear divergence between the two markets underscores the vital influence of institutional and macroeconomic environments on crypto asset behavior. The results challenge the weak-form Efficient Market Hypothesis while supporting the Adaptive Markets Hypothesis, offering a novel analytical and strategic framework for digital asset investment.

Keywords: Cryptocurrency; Spatial–Deep Hybrid Model; Spatial Econometrics; Deep Reinforcement Learning; Return Prediction; Iranian and U.S. Markets

Citation: Zamanian, A., Aslani, M., & Hematfar, M. (2026). Comparative Analysis of Cryptocurrency Market Behavior in Iran and the United States Using Hybrid Deep Learning Models and Indigenous Trading Strategy Design. *Accounting, Finance and Computational Intelligence*, 4(3), 1–32.



Copyright: © 2026 by the authors. Published under the terms and conditions of Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License.

Extended Abstract**Introduction**

In recent years, the global financial system has witnessed an unprecedented transformation driven by blockchain technology and the rapid proliferation of cryptocurrencies ([Banerjee & Khan, 2025](#)). Cryptocurrencies, as decentralized digital assets based on cryptographic protocols, have disrupted the conventional understanding of money, ownership, and trust by removing financial intermediaries and relying on peer-to-peer networks ([Poskart, 2022](#)). Since the introduction of Bitcoin in 2009, the cryptocurrency market has evolved into a multi-trillion-dollar ecosystem influencing both individual and institutional investment decisions ([Kang et al., 2025](#)). Recent empirical research has demonstrated that cryptocurrencies serve not only as alternative payment systems but also as speculative assets and hedging instruments in diversified portfolios ([Lee, 2024](#)).

The growing volatility and nonlinear dynamics of cryptocurrency prices have attracted increasing academic attention across economic, behavioral, and computational domains ([Koutrouli et al., 2025](#)). Unlike traditional financial assets, cryptocurrencies lack intrinsic value or centralized regulation, and their pricing behavior is shaped by a complex interplay between technological innovation, investor sentiment, and macroeconomic uncertainty ([Joebges et al., 2025](#)). Consequently, understanding and forecasting their price movements remain among the most challenging topics in financial research ([He et al., 2024](#)). Traditional econometric models such as ARIMA, GARCH, and VAR have been applied to predict financial time series, yet they often fail to capture the structural nonlinearity, regime-switching patterns, and contagion effects inherent in cryptocurrency markets ([Mohammad Sharifi et al., 2021](#); [Samavi et al., 2022](#)).

To overcome these limitations, the integration of machine learning and deep learning algorithms has emerged as a powerful alternative. Recurrent Neural Networks (RNNs), Long Short-Term Memory (LSTM) architectures, and Gated Recurrent Units (GRU) have proven effective in capturing sequential dependencies and temporal volatility ([Dutta et al., 2020](#); [Sagheer et al., 2025](#)). In particular, hybrid models combining convolutional neural networks (CNNs) with LSTM layers have achieved superior performance in modeling complex financial patterns ([Chowdhury et al., 2020](#)). Further, ensemble learning and transformer-based frameworks have enabled the extraction of latent nonlinear structures, significantly improving predictive accuracy ([Bouteska et al., 2024](#)).

Alongside the computational dimension, behavioral and psychological factors also play a crucial role in cryptocurrency price dynamics. Contrary to the Efficient Market Hypothesis ([Ahadzadeh et al., 2023](#)), multiple studies suggest that investor decisions are frequently driven by herd behavior, emotional contagion, and media-induced expectations rather than rational valuation ([Askarzadeh & Rouhi, 2022](#); [Shojaei & Abdolbaghi Ataabadi, 2023](#)). In emerging markets with limited transparency and regulatory oversight, social sentiment and search intensity have demonstrated strong predictive power for short-term returns ([Ghorbani et al., 2022](#); [Habibi Rad & Panahi, 2021](#)).

Additionally, cross-market interdependencies between cryptocurrencies and macroeconomic indicators have intensified. Evidence reveals that cryptocurrency shocks can propagate across markets and geographical boundaries, leading to contagion effects ([Makarov & Schoar, 2020](#); [Sadeqian et al., 2023](#)). These spillover dynamics suggest the necessity of spatial econometric approaches capable of modeling inter-asset linkages and feedback mechanisms ([Rezaqoli Zadeh et al., 2024](#)). Recent studies have highlighted that while on-chain metrics dominate pricing in developed economies, macroeconomic drivers such as

inflation, currency depreciation, and political instability govern cryptocurrency behavior in emerging markets (El Hajj & Farran, 2024; Goudarzi Farahani et al., 2022).

From a regulatory standpoint, cryptocurrencies embody a dual nature — as enablers of financial inclusion and as potential threats to monetary stability (Joebges et al., 2025). In developed markets, institutional adoption and legal clarity have enhanced liquidity and investor confidence (Dionysopoulos et al., 2024), whereas in developing nations like Iran, the absence of regulatory frameworks, coupled with currency volatility, has rendered cryptocurrency trading a speculative and partially substitutive financial activity (Ghamami & Alipour, 2022; Nourouzi & Shabani, 2021). Furthermore, accounting and valuation standards for digital assets remain underdeveloped, exacerbating uncertainty in financial reporting and corporate governance (Hosseinzadeh et al., 2022; La'i Bar & Ghasemi, 2024).

This study thus seeks to bridge these conceptual and methodological gaps by developing a spatial–deep hybrid forecasting model to analyze cryptocurrency market behavior in Iran and the United States. By combining spatial econometric analysis with advanced deep learning architectures and reinforcement-based trading optimization, the study aims to capture the multidimensional dependencies underlying cryptocurrency dynamics across distinct institutional and economic contexts.

Methods and Materials

This applied–developmental study adopted a quantitative, comparative research design. Data were collected from 32 leading cryptocurrencies covering the period from 2018 to 2024. The dataset included daily price returns, macroeconomic variables, on-chain network metrics, and market sentiment indicators derived from social media analytics and Google search trends.

The hybrid framework consisted of three primary modules. First, spatial econometric models (Spatial Durbin and Spatial Autoregressive models) were employed to identify contagion and network spillover effects across cryptocurrencies. Second, deep learning architectures — including Graph Neural Networks (GNNs), CNN-LSTM hybrids with attention mechanisms, and Transformer-based temporal encoders — were integrated to detect nonlinear temporal dependencies. Third, a deep reinforcement learning (DRL) agent was developed to generate adaptive trading strategies based on model outputs and reward-maximization criteria.

Model performance was benchmarked against eight comparative baselines, including ARIMA, GARCH, LSTM, GRU, Random Forest, LightGBM, CEEMD-DL, and hybrid ARIMA–DL models. Accuracy and robustness were evaluated using Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), R-squared, and the Diebold–Mariano test for forecast comparison.

Findings

The empirical analysis demonstrated that the proposed spatial–deep hybrid model significantly outperformed traditional and single-component deep learning frameworks across all evaluation metrics. The model achieved an average RMSE reduction of 24.6% and a MAPE improvement of 31.8% relative to the strongest benchmark.

In the U.S. market, on-chain variables such as hash rate, transaction volume, and active addresses were the most influential predictors of cryptocurrency returns. Conversely, in Iran, macroeconomic indicators — including inflation rate, exchange rate volatility, and policy uncertainty — exerted the strongest effects on price behavior. This divergence underscores the dominant influence of institutional and structural factors in shaping market dynamics.

Spatial analysis revealed substantial spillover effects among major cryptocurrencies, especially within technologically similar clusters (e.g., Ethereum, Binance Coin, and Solana). Bitcoin served as the central contagion node, transmitting volatility across the network during market turbulence. In Iran, spillovers were predominantly mediated through macroeconomic linkages rather than technological interconnections.

The hybrid model also generated trading strategies using the reinforcement learning module, producing an annualized return of 67.89% (Sharpe ratio = 1.89) in the U.S. market and 51.23% (Sharpe ratio = 1.48) in the Iranian market. These results outperformed static buy-and-hold strategies by 43% and 37%, respectively. Sensitivity analysis indicated that incorporating sentiment indices enhanced short-term accuracy, while adding spatial contagion features improved medium-term forecast stability.

Furthermore, the study found empirical evidence challenging the weak-form Efficient Market Hypothesis, as the model captured consistent predictive patterns in both markets. Temporal asymmetry and volatility clustering suggested that cryptocurrency markets operate under the Adaptive Market Hypothesis, wherein efficiency fluctuates with behavioral and institutional factors.

Discussion and Conclusion

The findings of this research contribute to the growing literature on hybrid forecasting and the behavioral economics of digital assets by demonstrating that cryptocurrency market behavior is governed by a combination of structural, technological, and emotional dimensions. The superior performance of the spatial-deep hybrid model confirms that integrating spatial econometric reasoning with nonlinear deep learning architectures can capture complex interdependencies overlooked by traditional models. This synthesis enhances both predictive accuracy and economic interpretability, bridging the gap between computational finance and applied econometrics.

The comparative analysis between Iran and the United States highlights how contextual factors shape the operational logic of cryptocurrency markets. In a developed, transparent environment like the U.S., blockchain activity and investor confidence determine price trajectories, whereas in an emerging market constrained by monetary instability, cryptocurrencies act as inflation hedges and speculative instruments. This asymmetry reflects not merely economic disparities but differences in trust systems, regulatory maturity, and access to international exchanges.

The behavioral component further reinforces the importance of sentiment-driven dynamics in volatile and immature markets. In Iran, where information asymmetry prevails and institutional oversight is weak, social and emotional signals play a disproportionately large role in influencing investment decisions. In contrast, the U.S. market exhibits adaptive efficiency, where behavioral effects are transient and self-correcting. Such duality supports the view that cryptocurrencies do not conform to a single efficiency paradigm but evolve according to the adaptive interaction of technology, policy, and human psychology.

The model's ability to identify spillover networks and contagion pathways provides novel insights into systemic risk and market interconnectivity. Mapping the spatial dependencies among cryptocurrencies enables regulators and portfolio managers to anticipate cross-asset shocks and develop targeted risk-mitigation strategies. In this regard, the research moves beyond mere prediction to offer structural understanding of volatility transmission and information diffusion within crypto ecosystems.

From a methodological standpoint, the study demonstrates that fusing machine intelligence with spatial analytics is not only feasible but advantageous for analyzing digital financial phenomena. The proposed framework can serve as a foundation for future models that incorporate explainable AI (XAI) techniques, enhancing transparency and interpretability in financial machine learning applications.

Ultimately, this research underscores that cryptocurrency markets represent adaptive, multilayered systems wherein institutional context, collective behavior, and computational complexity intersect. Recognizing these interdependencies allows policymakers, investors, and scholars to move beyond reductionist perspectives and toward a systemic understanding of how digital assets function within global and local economies.

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.

تحلیل مقایسه‌ای رفتار بازار رمزارز در ایران و آمریکا با استفاده از مدل‌های هیبریدی یادگیری عمیق و طراحی استراتژی معاملاتی بومی



تاریخچه مقاله

تاریخ دریافت: ۲۵ تیر ۱۴۰۴

تاریخ بازنگری: ۸ آبان ۱۴۰۴

تاریخ پذیرش: ۱۵ آبان ۱۴۰۴

تاریخ انتشار: ۱ شهریور ۱۴۰۵

۱. علیرضا زمانیان¹: دانشجوی دکتری، گروه حسابداری، واحد بروجرد، دانشگاه آزاد اسلامی، بروجرد، ایران

۲. محمد اسلانی^{2*}: استادیار، گروه حسابداری، واحد تویسرکان، دانشگاه آزاد اسلامی، تویسرکان، ایران. ایمیل: mohammad.aslani@iau.ac.ir (نویسنده مسئول)

۳. محمود همت فر³: دانشیار، گروه حسابداری، واحد بروجرد، دانشگاه آزاد اسلامی، بروجرد، ایران

چکیده

هدف پژوهش، توسعه یک مدل هیبریدی فضایی-یادگیری عمیق برای پیش‌بینی بازدهی رمزارزها و مقایسه رفتار بازار رمزارز در ایران و آمریکا به منظور طراحی استراتژی‌های معاملاتی بومی و بهینه است. این پژوهش از نوع کاربردی-توسعه‌ای و با رویکرد کمی انجام شده است. داده‌های ۳۲ رمزارز برتر بازار در بازه زمانی ۲۰۱۸ تا ۲۰۲۴ از منابع معتبر جهانی گردآوری گردید. مدل تحقیق شامل سه لایه اصلی بود: (۱) اقتصادسنجی فضایی جهت مدل‌سازی اثرات سرایت و روابط شبکه‌ای رمزارزها؛ (۲) مدل‌های یادگیری عمیق شامل شبکه‌های عصبی گرافی، CNN-LSTM با مکانیزم توجه، و ترنسفورمر برای شناسایی الگوهای غیرخطی زمانی؛ و (۳) یادگیری تقویتی عمیق برای طراحی استراتژی معاملاتی. ارزیابی مدل‌ها با آزمون‌های آماری از جمله دیولد-ماریانو و مقایسه با هشت مدل معیار انجام شد. نتایج نشان داد مدل هیبریدی فضایی-یادگیری عمیق عملکرد به مراتب بهتری نسبت به مدل‌های کلاسیک و تک‌مؤلفه‌ای دارد. در بازار آمریکا، متغیرهای درون‌زنجیره‌ای و شاخص‌های فنی بیشترین اثر را بر قیمت رمزارزها داشتند، در حالی که در ایران، متغیرهای کلان اقتصادی نظیر نرخ ارز غیررسمی و تورم نقش غالب داشتند. استراتژی معاملاتی مبتنی بر مدل در آمریکا بازده سالانه ۶۷.۸۹٪ با نسبت شارپ ۱.۸۹ و در ایران بازده ۵۱.۲۳٪ با نسبت شارپ ۱.۴۸ ایجاد کرد. مدل پیشنهادی با ترکیب وابستگی‌های فضایی و الگوهای زمانی غیرخطی، دقت پیش‌بینی و تفسیرپذیری اقتصادی را همزمان ارتقا داد. تفاوت عملکرد در دو بازار بیانگر اهمیت محیط نهادی و اقتصادی در رفتار رمزارزها است. یافته‌ها فرضیه بازار کارایی ضعیف را به چالش کشیده و فرضیه بازار انطباقی را تأیید می‌کنند. پژوهش مسیر جدیدی برای تحلیل و سرمایه‌گذاری در بازارهای رمزارز فراهم ساخت.

کلیدواژه‌گان: رمزارز؛ مدل هیبریدی فضایی-یادگیری عمیق؛ اقتصادسنجی فضایی؛ یادگیری تقویتی؛ پیش‌بینی بازدهی؛ بازار ایران و آمریکا

شیوه استناددهی: زمانیان، علیرضا، اسلانی، محمد، و همت فر، محمود. (۱۴۰۵). تحلیل مقایسه‌ای رفتار بازار رمزارز در ایران و آمریکا با استفاده از مدل‌های هیبریدی یادگیری عمیق و طراحی استراتژی معاملاتی بومی. *حسابداری، امور مالی و هوش محاسباتی*، ۴(۳)، ۱-۳۳.



در دهه‌های اخیر، ظهور فناوری بلاک‌چین و گسترش رمزارزها به‌عنوان یکی از مهم‌ترین تحولات نظام مالی جهانی، زمینه‌ساز شکل‌گیری پارادایم جدیدی در حوزه مبادلات، سرمایه‌گذاری و سیاست‌گذاری پولی شده است (Banerjee & Khan, 2025). رمزارزها یا دارایی‌های دیجیتال مبتنی بر رمزنگاری، با حذف نهادهای مالی واسطه و تمرکززدایی از نظام بانکی سنتی، مفهوم پول، مالکیت و اعتماد را دگرگون کرده‌اند (Poskart, 2022). این پدیده که ابتدا با معرفی بیت‌کوین در سال ۲۰۰۹ آغاز شد، امروزه به بازاری چند هزار میلیارد دلاری با صدها رمزارز فعال تبدیل شده است (Kang et al., 2025). بر اساس مطالعات اخیر، رمزارزها نه تنها ابزار پرداخت و ذخیره ارزش محسوب می‌شوند، بلکه به‌عنوان دارایی‌های نوظهور در سبد سرمایه‌گذاری شرکت‌ها و سرمایه‌گذاران نهادی نیز جایگاه ویژه‌ای یافته‌اند (Lee, 2024).

رشد سریع بازار رمزارزها در سال‌های اخیر باعث شده تا پژوهشگران از دیدگاه‌های اقتصادی، فناوریانه، رفتاری و حقوقی به تحلیل آن بپردازند (Koutrouli et al., 2025). یکی از پرسش‌های اساسی در این زمینه، ماهیت قیمت‌گذاری رمزارزها و عوامل مؤثر بر نوسانات شدید آن‌هاست. برخلاف دارایی‌های سنتی مانند سهام یا طلا که دارای پشتوانه فیزیکی یا سود تقسیمی هستند، ارزش رمزارزها بر مبنای اعتماد، شبکه کاربران، تقاضای بازار و نوآوری فناوریانه شکل می‌گیرد (Joebges et al., 2025). در نتیجه، تعیین ارزش ذاتی و پیش‌بینی دقیق قیمت رمزارزها به چالشی پیچیده برای پژوهشگران مالی و تحلیلگران داده تبدیل شده است (He et al., 2024).

از منظر تاریخی، مدل‌های کلاسیک سری‌های زمانی نظیر ARIMA، GARCH و VAR در پیش‌بینی قیمت دارایی‌ها مورد استفاده قرار گرفته‌اند (Mohammad Sharifi et al., 2021). اما این مدل‌ها در مواجهه با ویژگی‌های خاص بازار رمزارزها نظیر نوسانات شدید، وابستگی‌های غیرخطی و سرایت بین رمزارزها، کارایی محدودی دارند (Samavi et al., 2022). این ضعف موجب شده است تا پژوهشگران به سمت استفاده از مدل‌های یادگیری ماشین و یادگیری عمیق حرکت کنند که توانایی استخراج الگوهای پیچیده از داده‌های حجیم و چندبعدی را دارند (Sagheer et al., 2025).

در دهه اخیر، کاربرد مدل‌های یادگیری عمیق در تحلیل داده‌های مالی رشد چشمگیری یافته است. شبکه‌های عصبی بازگشتی (RNN)، شبکه‌های حافظه بلندمدت (LSTM) و واحدهای دروازه‌ای تکرارشونده (GRU) از جمله معماری‌هایی هستند که در پیش‌بینی سری‌های زمانی مالی، به‌ویژه قیمت رمزارزها، به کار گرفته شده‌اند (Dutta et al., 2020). برای نمونه، مدل GRU با ترکیب حافظه زمانی و قابلیت همگرایی سریع، عملکرد بهتری نسبت به مدل‌های سنتی نشان داده است (Chowdhury et al., 2020). در همین راستا، مدل‌های ترکیبی مانند CEEMD-DL نیز با هدف بهبود دقت پیش‌بینی و استخراج الگوهای پنهان در داده‌های رمزارزها توسعه یافته‌اند (Sayyadinejad et al., 2023). پژوهش‌های اخیر ثابت کرده‌اند که ترکیب الگوریتم‌های یادگیری عمیق با روش‌های اقتصادسنجی، موجب افزایش تفسیرپذیری و پایداری مدل‌ها می‌شود (Bouteska et al., 2024).

علاوه بر جنبه پیش‌بینی، جنبه‌های رفتاری بازار رمزارز نیز از اهمیت بالایی برخوردار است. نظریه بازار کارا (Ahadzadeh et al., 2023) بیان می‌کند که قیمت‌ها تمامی اطلاعات در دسترس را منعکس می‌کنند، اما شواهد متعددی در بازار رمزارزها این فرض را به چالش کشیده است (Askarzadeh & Rouhi, 2022). وجود رفتارهای هیجانی و تصمیم‌گیری‌های غیرعقلانی سرمایه‌گذاران منجر به بروز پدیده‌هایی چون رفتار گله‌ای و معاملات نویزی شده است (Shojaei & Abdolbaghi Ataabadi, 2023). به‌ویژه در بازارهای نوظهور و فاقد چارچوب‌های نظارتی مستحکم، تأثیر احساسات جمعی و اخبار رسانه‌ای بر نوسانات قیمتی بسیار شدیدتر است (Ghorbani et al., 2022). در این میان، تحلیل احساسات کاربران در شبکه‌های اجتماعی توانسته است همبستگی بالایی با تغییرات قیمت بیت‌کوین نشان دهد (Habibi Rad & Panahi, 2021). این یافته‌ها تأیید می‌کند که بازار رمزارزها نه تنها از منطق اقتصادی کلاسیک، بلکه از الگوهای رفتاری و روان‌شناختی نیز تبعیت می‌کند (Ebrahimpour et al., 2025).

از سوی دیگر، پدیده نوسانات شدید و سرایت بین رمزارزها یکی از ویژگی‌های ذاتی این بازار است که تحلیل آن نیازمند رویکردهای چندبعدی است (Sadeqian et al., 2023). پژوهش‌های مبتنی بر مدل‌های کوپلا و همبستگی شرطی پویا (DCC-GARCH) نشان داده‌اند که شوک‌های قیمتی در یک رمزارز می‌تواند به‌سرعت به سایر رمزارزها منتقل شود (Kim et al., 2020). این پویایی‌های شبکه‌ای سبب شده است که مفهوم وابستگی فضایی و مدل‌های اقتصادسنجی فضایی در تحلیل بازار رمزارز مورد توجه قرار

گیرد (Makarov & Schoar, 2020). در چنین شرایطی، استفاده از مدل‌های هیبریدی اقتصادسنجی فضایی-یادگیری عمیق که بتوانند اثرات سرریز و روابط بین رمزارزها را به‌صورت همزمان با الگوهای زمانی غیرخطی مدل‌سازی کنند، ضرورت می‌یابد (Rezaqoli Zadeh et al., 2024).

عوامل کلان اقتصادی نیز در تحلیل رفتار بازار رمزارز نقشی کلیدی دارند. در کشورهای توسعه‌یافته، رمزارزها عمدتاً به‌عنوان ابزار سرمایه‌گذاری و تنوع پرتفوی در نظر گرفته می‌شوند، در حالی که در کشورهای درحال توسعه، نقش آن‌ها به‌عنوان ابزار پوشش ریسک تورمی و جایگزین دارایی‌های سنتی پررنگ‌تر است (El Hajj & Farran, 2024). مطالعه بازار ایران نشان می‌دهد که متغیرهایی چون نرخ ارز غیررسمی، تورم و عدم قطعیت سیاست اقتصادی تأثیر قابل توجهی بر بازده رمزارزها دارند (Goudarzi Farahani et al., 2022). در مقابل، در بازار آمریکا شاخص‌های درون‌زنجیره‌ای، نوآوری فناورانه و فعالیت کاربران شبکه اهمیت بیشتری در تعیین قیمت دارند (Lee, 2024). این تفاوت‌های ساختاری ناشی از محیط نهادی و زیرساخت‌های قانونی متفاوت دو بازار است (Ghamami & Alipour, 2022).

از دیدگاه سیاست‌گذاری، رمزارزها هم فرصت و هم تهدید محسوب می‌شوند. از یک سو، آن‌ها می‌توانند موجب شمول مالی و تسهیل پرداخت‌های بین‌المللی شوند (El Hajj & Farran, 2024) و از سوی دیگر، به‌دلیل نبود نظارت متمرکز، تهدیدی برای ثبات مالی و کنترل‌های پولی به شمار می‌روند (Joebges et al., 2025). در ایران، مسئله حقوقی و فقهی رمزارزها هنوز در حال بررسی است و مواضع مختلفی درباره مشروعیت استخراج و مبادله آن وجود دارد (Nourouzi & Shabani, 2021). بررسی‌های تطبیقی بین ایران و ایالات متحده نشان می‌دهد که تفاوت در نظام حقوقی و نظارتی، تأثیر مستقیمی بر نقدشوندگی، کارایی و رفتار سرمایه‌گذاران در بازار دارد (Ghamami & Alipour, 2022). در سال‌های اخیر، تلاش‌هایی برای تحلیل پیوند بین بازار رمزارز و سایر بازارهای مالی صورت گرفته است. برای نمونه، ارتباط بین بیت‌کوین و شاخص‌های سهام آمریکا، طلا و دلار در شرایط مختلف بازار مورد بررسی قرار گرفته است (Kim et al., 2020; Mokni & Noomen Ajmi, 2021). نتایج این مطالعات نشان داده‌اند که در دوره‌های بحران مالی، همبستگی رمزارزها با دارایی‌های امن افزایش می‌یابد و نقش رمزارزها به‌عنوان «پناهگاه امن» تقویت می‌شود (Petukhina et al., 2021). از سوی دیگر، برخی تحقیقات تأیید کرده‌اند که اضافه کردن رمزارزها به سبد سرمایه‌گذاری می‌تواند نسبت ریسک-بازده را بهبود بخشد، اگرچه باید محدودیت نقدینگی و ریسک‌های سیستماتیک نیز مدنظر قرار گیرد (Weng et al., 2020).

در حوزه نظری، مفهوم «بازارهای تطبیقی» نیز در تحلیل رفتار رمزارزها اهمیت یافته است. این نظریه بیان می‌کند که کارایی بازار در طول زمان و بر اساس شرایط محیطی تغییر می‌کند (Ahadzadeh et al., 2023). بنابراین، ممکن است یک بازار رمزارز در دوره‌ای کارا و در دوره دیگر ناکارا باشد، بسته به تعداد بازیگران و میزان اطلاعات در دسترس (Liu & Tsyvinski, 2021). از منظر تجربی، شواهد نشان می‌دهد که رفتار سرمایه‌گذاران در بازارهای رمزارز ترکیبی از منطق اقتصادی و هیجانات رفتاری است (Ghavami Pour Sarashkeh & Mahmudi, 2025).

از دیدگاه فنی، مطالعات متعددی به توسعه مدل‌های پیش‌بینی مبتنی بر هوش مصنوعی پرداخته‌اند. مدل‌های LightGBM (Xiaolei et al., 2020)، الگوریتم‌های ترکیبی CNN-LSTM (He et al., 2024) و یادگیری تقویتی عمیق با مکانیزم توجه چندبعدی (Weng et al., 2020) از جمله موفق‌ترین معماری‌ها در این حوزه هستند که توانسته‌اند الگوهای پنهان را در داده‌های قیمتی استخراج کنند. با این حال، اکثر این مدل‌ها در بازارهای توسعه‌یافته نظیر آمریکا یا اروپا آزموده شده‌اند و قابلیت انطباق آن‌ها با شرایط خاص بازارهای نوظهور همچون ایران کمتر بررسی شده است (Samavi et al., 2022). در کنار جنبه‌های فنی، پژوهش‌های متعددی نیز به تحلیل اثر احساسات، جست‌وجوهای اینترنتی و متغیرهای اجتماعی بر قیمت رمزارزها پرداخته‌اند. حجم جست‌وجوی واژه‌هایی مانند "Bitcoin" در گوگل، شاخصی از علاقه عمومی و انتظارات سرمایه‌گذاران به شمار می‌آید و با افزایش قیمت همبستگی مثبت دارد (Habibi Rad & Panahi, 2021). این متغیر به‌ویژه در بازار ایران، که داده‌های رسمی و شفافیت مالی محدود است، می‌تواند به‌عنوان شاخص پیش‌نگر تغییرات قیمت مورد استفاده قرار گیرد (Javaheri et al., 2024).

از جنبه حسابداری و مالی نیز، ظهور دارایی‌های دیجیتال چالش‌های متعددی برای نظام‌های گزارشگری ایجاد کرده است (La' Bar & Ghasemi, 2024). نبود استانداردهای حسابداری مشخص برای طبقه‌بندی و اندازه‌گیری رمزارزها موجب ابهام در ارزیابی ارزش واقعی دارایی‌های دیجیتال شده است (Hosseinazadeh et al., 2022). همچنین، تأثیر نوسانات شدید رمزارزها بر نقدینگی شرکت‌ها و مدیریت ریسک مالی نیز مورد توجه قرار گرفته است (Lee, 2024).

در این میان، اهمیت بررسی مقایسه‌ای بازار رمزارز در ایران و آمریکا از آن جهت است که دو بازار یادشده از نظر ساختار اقتصادی، محیط نظارتی، رفتار سرمایه‌گذاران و میزان بلوغ فناوریانه تفاوت‌های بنیادینی دارند (Dionysopoulos et al., 2024). بازار آمریکا به‌عنوان یکی از نظام‌مندترین بازارهای رمزارز با حضور سرمایه‌گذاران نهادی و صندوق‌های ETF، از شفافیت بالا و دسترسی گسترده به داده‌ها برخوردار است، در حالی که بازار ایران تحت تأثیر تحریم‌ها، محدودیت‌های ارزی و نبود قوانین جامع، رفتاری متفاوت و پیچیده‌تر از خود نشان می‌دهد (Nourouzi & Shabani, 2021). مطالعات داخلی نظیر (Ghamami & Alipour, 2022; Goudarzi Farahani et al., 2022; Javaheri et al., 2024) نشان داده‌اند که بازار رمزارز در ایران علاوه بر عوامل فنی، به‌شدت تحت تأثیر متغیرهای کلان اقتصادی و سیاسی است. در مقابل، پژوهش‌های بین‌المللی مانند (Banerjee & Khan, 2025; Kang et al., 2025; Koutrouli et al., 2025) بیشتر بر جنبه‌های فناوریانه، ساختار شبکه‌ای و ادغام رمزارزها با بازارهای جهانی تمرکز داشته‌اند. این تمایز آشکار، ضرورت بررسی تطبیقی میان دو بازار را تقویت می‌کند تا بتوان الگوهای مشترک و متفاوت را شناسایی کرد. در مجموع، مرور ادبیات نشان می‌دهد که با وجود رشد سریع پژوهش‌ها در زمینه تحلیل رمزارزها، هنوز شکاف‌های پژوهشی قابل توجهی باقی مانده است. اول، مطالعات اندکی به مقایسه هم‌زمان بازارهای توسعه‌یافته و نوظهور از منظر اقتصادی و فناوریانه پرداخته‌اند. دوم، مدل‌های یادگیری عمیق غالباً فاقد تفسیرپذیری اقتصادی هستند و نیاز به ادغام با مدل‌های ساختاری دارند. سوم، نقش متغیرهای محلی و نهادی در شکل‌گیری رفتار رمزارزها در کشورهایی مانند ایران هنوز به‌طور جامع بررسی نشده است (Bouteska et al., 2023; Msomi & Nyandeni, 2023). با توجه به آنچه بیان شد، پژوهش حاضر با هدف تحلیل مقایسه‌ای رفتار بازار رمزارز در ایران و آمریکا با بهره‌گیری از مدل‌های هیبریدی یادگیری عمیق و طراحی استراتژی‌های معاملاتی بومی انجام می‌شود.

روش پژوهش و مواد

این پژوهش از یک رویکرد ترکیبی^۱ کمی با ماهیت کاربردی-توسعه‌ای استفاده می‌کند که هدف آن تحلیل مقایسه‌ای رفتار بازار رمزارز در دو محیط متفاوت (ایران و آمریکا)، پیش‌بینی قیمت و طراحی استراتژی‌های معاملاتی بومی است. طرح پژوهش به‌صورت پنل دینامیک^۲ با ساختار داده‌های پانلی نامتوازن^۳ برای ۳۲ رمزارز برتر در بازه زمانی ۰۱/۰۱/۲۰۱۸ تا ۳۱/۱۲/۲۰۲۴ (بیش از ۲۵۵۵ روز معاملاتی) است. این بازه زمانی به‌عمد انتخاب شده تا دوره‌های مختلف بازار شامل بحران‌های عمده (افت ۲۰۱۸، بحران Terra/Luna و FTX در ۲۰۲۲)، دوره‌های رونق (صعود ۲۰۲۰-۲۰۲۱، بازگشت ۲۰۲۳-۲۰۲۴) و رویدادهای خاص هر بازار (تحریم‌های ایران، تصویب ETF بیت‌کوین در آمریکا) را پوشش دهد. این پژوهش، برخلاف مطالعات قبلی که معمولاً یک بازار واحد را بررسی می‌کنند، این تحقیق یک مدل دوگانه^۴ طراحی می‌کند که به‌صورت هم‌زمان دو بازار را با در نظر گرفتن تفاوت‌های ساختاری، نهادی و رفتاری آن‌ها مدل‌سازی می‌نماید. این رویکرد امکان شناسایی اثرات خاص هر بازار^۵ و اثرات مشترک^۶ را فراهم می‌آورد. متغیرهای مورد استفاده شامل داده‌های قیمتی، شاخص‌های تکنیکال، متغیرهای زنجیره‌ای، شاخص‌های کلان بازار و داده‌های احساسات و توجه عمومی است که در جدول ۲ قابل مشاهده است. همچنین داده‌ها از منابع معتبری همچون بایننس، کوین‌گکو، گلس‌نود و بلومبرگ با استفاده از برنامه نویسی RStudio و Python جمع‌آوری و استخراج شده‌اند. جامعه آماری این پژوهش شامل کلیه رمزارزهایی است که در بازه زمانی مورد مطالعه در هر دو بازار ایران و آمریکا قابل معامله بوده‌اند. با این حال، با توجه به محدودیت‌های عملی و ضرورت تمرکز بر دارایی‌های با اهمیت و نقدشوندگی کافی، از روش نمونه‌گیری هدفمند معیاری^۷ استفاده شده است. معیارهای انتخاب رمزارزها عبارتند از:

۱. معیار نقدشوندگی: حجم معاملات روزانه حداقل ۱۰ میلیون دلار در بازار جهانی

۲. معیار سرمایه بازار: قرارگیری در رتبه ۱۰۰ برتر CoinMarketCap یا CoinGecko در حداقل ۸۰٪ روزهای دوره مطالعه

¹ Mixed-Method

² Dynamic Panel

³ Unbalanced Panel Data

⁴ Dual-Market Model

⁵ Market-Specific Effects

⁶ Common Global Effects


⁷ Purposive Criterion Sampling

۳. معیار تداوم داده: دسترسی به داده‌های مستمر و قابل اعتماد برای تمام متغیرها در کل دوره زمانی

۴. معیار قابلیت دسترسی در ایران: امکان معامله (مستقیم یا غیرمستقیم) در بازار ایران از طریق صرافی‌های داخلی یا پلتفرم‌های P2P

۵. معیار تنوع فناوری: نمایندگی از دسته‌های مختلف رمزارزها (ذخیره ارزش، پلتفرم قراردادهای هوشمند، DeFi، NFT/Metaverse، استیبل کوین)

بر اساس این معیارها، ۳۲ رمزارز انتخاب شده‌اند که در جدول ۱ فهرست شده‌اند. این نمونه تقریباً ۷۵٪ کل سرمایه بازار رمزارزها را پوشش می‌دهد و نمایندگی مناسبی از تنوع بازار فراهم می‌آورد. روش‌شناسی این مطالعه بر پایه یک رویکرد هیبریدی سه‌لایه استوار است که اقتصادسنجی فضایی و یادگیری عمیق را به صورت هم‌افزا ترکیب می‌کند. در لایه اول، مدل‌های اقتصادسنجی فضایی شامل مدل خودرگرسیون فضایی، مدل دوربین فضایی و مدل برداری خودرگرسیون فضایی-زمانی تعمیم‌یافته است که این سه مدل با همدیگر مدل ترکیبی تحلیل پیش‌بینانه چند مرحله‌ای^۱ را تشکیل می‌دهند. که با استفاده از ماتریس‌های وزن فضایی پویا (مبتنی بر همبستگی متحرک، مشابهت تکنولوژیکی و نقدشوندگی) برای شناسایی روابط فضایی بین رمزارزها، اثرات سرریز و کانال‌های انتقال شوک به کار گرفته می‌شوند. در لایه دوم، معماری‌های یادگیری عمیق پیشرفته شامل شبکه عصبی کانولوشنی-حافظه بلندمدت کوتاه‌مدت با مکانیزم توجه برای استخراج الگوهای زمانی، شبکه‌های عصبی گرافی (کانولوشن گرافی و توجه گرافی) برای مدل‌سازی روابط شبکه‌ای، و شبکه‌های تبدیل‌کننده فضایی برای کدگذاری همزمان اطلاعات فضایی-زمانی آموزش داده می‌شوند. در لایه سوم، خروجی‌های این مدل‌ها از طریق یادگیری گروهی انباشته با فرامدل مبتنی بر تقویت گرادیان شدید و میانگین‌گیری بیزین مدل ترکیب شده و پیش‌بینی‌های نهایی قیمت تولید می‌گردند. در نهایت، این پیش‌بینی‌ها در یک چارچوب یادگیری تقویتی عمیق (شامل شبکه کیو عمیق، بهینه‌سازی سیاست مجاور و عامل-منتقد ناهمزمان) و بهینه‌سازی پرتفوی مبتنی بر میانگین-ارزش در معرض خطر شرطی و برابری ریسک پویا برای طراحی استراتژی‌های معاملاتی بهینه با حداکثر بازده تعدیل شده به ریسک به کارگیری می‌شوند. ارزیابی عملکرد مدل‌ها از طریق تحلیل گام‌به‌گام، آزمون بازگشتی و آزمون‌های آماری دقیق همچون آزمون دیبولد-مارینانو و مجموعه اطمینان مدل صورت می‌گیرد. بنابراین، پیش‌بینی دقیق قیمت و بازدهی رمزارزها به دلیل ویژگی‌های منحصر به فرد این بازارها از جمله نوسانات شدید، غیرخطی بودن روابط، وابستگی‌های پیچیده زمانی و مقطعی، و تأثیرپذیری از عوامل چندگانه بنیادی، تکنیکال، زنجیره‌ای و روان‌شناختی، نیازمند رویکردهای پیشرفته‌ای است که فراتر از مدل‌های سنتی سری زمانی عمل کنند. بنابراین، مدل مفهومی پژوهش به شرح زیر است:



شکل ۱. مدل مفهومی پژوهش

¹ Multi-Stage Predictive Analytics Hybrid Model

بر این اساس، این پژوهش از یک چارچوب مدل سازی سه مرحله ای استفاده می کند که شامل (۱) مدل های اقتصادسنجی فضایی برای شناسایی روابط ساختاری و اثرات فضایی، (۲) مدل های یادگیری عمیق برای کشف الگوهای غیرخطی پیچیده، و (۳) مدل های هیبریدی ترکیبی برای بهره گیری هم افزایی از هر دو رویکرد است. در ادامه، مدل های اصلی تحقیق به شرح زیر است:

مدل ترکیبی تحلیل پیش بینانه چند مرحله ای^۱

مدل ترکیبی تحلیل پیش بینانه چند مرحله ای در مرحله اول از اقتصادسنجی فضایی برای تحلیل روابط ساختاری و اثرات سرریز در بازارهای رمزارز استفاده می کند. این مدل ها به طور خاص برای لحاظ کردن تفاوت ها بین دو بازار (مانند آمریکا و ایران) در معادلات Dual-Market طراحی شده اند.

- برای آمریکا

$$R_{i,t}^{US} = p^{us} \sum_{j=1}^N w_{ij,t}^{us} R_{j,t}^{us} + \sum_{k=1}^K \beta_k^{us} X_{k,i,t}^{us} + \alpha_i^{us} + \lambda_t + \varepsilon_{i,t}^{us}$$

- برای ایران

$$R_{i,t}^{IR} = \rho^{IR} \sum_{j=1}^N w_{ij,t}^{IR} R_{j,t}^{IR} + \sum_{k=1}^K \beta_k^{IR} X_{k,i,t}^{IR} + \gamma_1 ER_{real,t} + \gamma_2 \Delta \pi_t + \gamma_3 EUP_{IR,t} + \alpha_i^{IR} + \lambda_t + \varepsilon_{i,t}^{IR}$$

که در آن:

- $R_{i,t}$: بازدهی لگاریتمی رمزارز i در زمان t ؛
 - ρ : ضریب خودهمبستگی فضایی (معیار قدرت اثرات سرریز بین رمزارزها)؛
 - $\omega_{ij,t}$: عنصر ماتریس وزن فضایی پویا بین رمزارزهای i و j در زمان t ؛
 - $X_{k,i,t}$: بردار متغیرهای توضیحی عمومی (مانند شاخص های فنی، احساسات، کلان جهانی)؛
 - $ER_{real,t}, \Delta \pi_t, EUP_{IR,t}$: متغیرهای خاص بازار ایران (مانند نرخ ارز حقیقی، تورم، شاخص عدم قطعیت سیاست اقتصادی ایران)؛
 - α_i^{IR} : اثرات ثابت رمزارز (کنترل ناهمگنی مشاهده نشده رمزارز)؛
 - λ_t : اثرات ثابت زمانی (کنترل شوک های جهانی مشترک)؛
 - $\varepsilon_{i,t}$: جمله خطای تصادفی (باقیمانده ها برای انتقال به مرحله ۲).
- ماتریس وزن فضایی پویا به صورت ترکیب وزنی سه ماتریس محاسبه می شود:

$$W_t = w_1 W_t^{corr} + w_2 W_t^{tech} + w_3 W_t^{liq}$$

که در آن: W_t^{corr} : ماتریس همبستگی پویای ۳۰ روزه بازدهی ها؛ W_t^{tech} : ماتریس مشابهت تکنولوژیکی (براساس کلاس رمزارز: پلتفرم، پرداخت، دیفای)؛ W_t^{liq} : ماتریس نقدشوندگی (براساس حجم معاملات روزانه)

- تجزیه اثرات

تجزیه اثرات بر اساس ضرایب برآورد شده $(\hat{\rho}, \hat{\beta}, \hat{\theta})$ انجام می شود:

$$\bar{M} = N^{-1} tr[(I_N - \rho W)^{-1} (I_N \beta_K + W \theta_K)] \quad \text{اثر مستقیم}^2$$

¹ Multi-Stage Predictive Analytics Hybrid Model (MSPAHM)

² Direct Effect

- اثر غیر مستقیم/سر ریز^۱: $\bar{M}_{indirect} = N^{-1}i_N[(I_N - \rho W)^{-1}(I_N\beta_K + W\theta_K)]i_N - \bar{M}_W$

- اثر کل^۲: $\bar{M}_{total} = \bar{M}_{direct} + \bar{M}_{indirect}$

در نهایت برای تحلیل پویایی‌های زمانی و فضایی به‌صورت همزمان و برداری بین ۳۲ رمز ارز از مدل خودرگرسیون فضایی-زمانی تعمیم‌یافته^۳ استفاده می‌شود که امکان ارزیابی شوک و سرایت ریسک را فراهم می‌کند که به صورت رابطه زیر است.

$$R_t = \sum_{l=1}^{\rho} A_l R_{t-1} + \sum_{l=1}^{\rho} B_l (W_l R_{t-1}) + \Gamma X_t + u_t$$

که در آن:

R_t : بردار $N \times 1$ بازدهی تمام رمزارزها در زمان t ؛

A_l : ماتریس ضرایب تأخیر زمانی مرتبه l ؛

B_l : ماتریس ضرایب تأخیر فضایی-زمانی مرتبه l ؛

Γ : ماتریس ضرایب متغیرهای برون‌زا X_t است.

مدل‌های یادگیری عمیق

۱.۲ مدل شبکه عصبی کانولوشنی-حافظه بلندمدت کوتاه‌مدت با مکانیزم توجه برای بازدهی^۴

این معماری، ابتدا از یک لایه کانولوشن^۵ برای استخراج ویژگی‌های محلی از داده‌های سری زمانی استفاده می‌کند، سپس از حافظه بلندمدت کوتاه‌مدت^۶ برای مدل‌سازی وابستگی‌های زمانی با مکانیزم توجه^۷ برای وزن‌دهی پویا استفاده می‌نماید.

الف) لایه کانولوشن یک‌بعدی

$$h_t^{conv} = \text{ReLU}(W_{conv} \cdot X_{i,t-w:t} + b_{conv})$$

جایی که $X_{i,t-w:t}$ بردار ورودی رمزارز i در پنجره زمانی w است.

ب) سلول حافظه بلندمدت کوتاه‌مدت

معادلات دروازه‌های سلول LSTM، که از خروجی CNN h_t^{conv} و حالت پنهان قبلی (h_{t-1}) استفاده می‌کند:

$$f_t = \sigma(W_f \cdot [h_{t-1}, h_t^{conv}] + b_f)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, h_t^{conv}] + b_i)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, h_t^{conv}] + b_c)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, h_t^{conv}] + b_o)$$

$$h_t = o_t \odot \tanh(C_t)$$

¹ Indirect Effect

² Total Effect

³ GSTAR-VAR

⁴ CNN-LSTM-Attention-Return

⁵ CNN

⁶ LSTM

⁷ Attention

ج) مکانیزم توجه چندسری برای وزن دهی پویا

برای محاسبه‌ی یک بردار زمینه وزن دهی شده (C_t) که مهم‌ترین حالات پنهان قبلی (h_k) را برجسته می‌کند:

$$e_{t,k} = v_a^T \tanh(W_a h_k + U_a h_t + b_a)$$

$$e_{t,k} = \frac{\exp(e_{t,k})}{\sum_{j=1}^T \exp(e_{t,j})}$$

$$C_t = \sum_{j=1}^T a_{t,k} h_k$$

در نهایت خروجی برای پیش بینی بازدهی به شرح زیر می‌باشد:


$$\hat{R}_{t,t+1} = W_y^R C_t + b_y^R$$

مدل هیبریدی اقتصادسنجی فضایی-یادگیری عمیق^۱

مدل ترکیبی اقتصادسنجی فضایی-یادگیری عمیق، چارچوبی نوآورانه است که نقاط قوت تحلیل‌های ساختاری^۲ و قدرت مدل‌سازی الگوهای غیرخطی (یادگیری عمیق) را برای بهبود دقت پیش‌بینی به صورت هم‌افزا ترکیب می‌کند. این رویکرد، ابتدا وابستگی‌های خطی و اثرات سرریز فضایی را حذف می‌کند و سپس باقی‌مانده‌های خالص غیرخطی را هدف مدل‌های پیشرفته‌ی یادگیری عمیق قرار می‌دهد تا کارایی و قابلیت تفسیر مدل را به طور همزمان افزایش دهد. نحوه این ترکیب لایه‌ای و جریان داده‌ها در نمودار ۲ قابل مشاهده است. بنابراین، در این تحقیق، با توجه به ماهیت پیچیده و چندبعدی بازار رمزارزها که همزمان دارای وابستگی‌های فضایی (سرریز بین رمزارزها)، پویایی‌های زمانی (الگوهای سری زمانی)، و روابط غیرخطی پیچیده است، از رویکرد هیبریدی اقتصادسنجی فضایی-یادگیری عمیق به عنوان مدل اصلی استفاده می‌شود. در این رویکرد، ابتدا مدل دوربین فضایی دوگانه برای شناسایی و برآورد اثرات فضایی مستقیم و غیرمستقیم متغیرهای فنی، متغیرهای زنجیره‌ای، احساسات بازار، و متغیرهای کلان به کار گرفته می‌شود. این امر با استفاده از یک ماتریس وزن فضایی پویا که ترکیبی از همبستگی پویای ۳۰ روزه، مشابهت تکنولوژیکی، و نقدشوندگی است، انجام می‌پذیرد. سپس، باقیمانده‌های این مدل که حاوی الگوهای غیرخطی و پیچیده‌ای هستند که مدل خطی نتوانسته کشف کند، همراه با متغیرهای اصلی، به معماری CNN-LSTM با مکانیزم توجه چندسری داده می‌شوند تا الگوهای زمانی غیرخطی پیچیده را شناسایی و مدل‌سازی کنند. این معماری ترکیبی امکان تجزیه اثرات را به جزء خطی-فضایی ساختاری (که روابط علی و اثرات سرریز را توضیح می‌دهد) و جزء غیرخطی یادگیری عمیق (که الگوهای پیچیده و تعاملات مرتبه بالا را کشف می‌کند) فراهم می‌آورد. علاوه بر این، برای افزایش دقت پیش‌بینی و استحکام نتایج، از مدل یادگیری گروهی انباشته استفاده می‌شود که با به کارگیری یک فرامدل با وزن‌های وابسته به زمینه، از مزایای هر رویکرد بهره‌برداری می‌کند. ساختار داده‌های تحقیق به شرح جدول ۱ و نحوه اندازه‌گیری و معرفی متغیرهای تحقیق در جدول ۲ قابل نمایش است.

¹ Spatial-Deep Hybrid Model

² SAR/SDM



شکل ۲. مراحل مدل هیبریدی

ساختار داده‌های تحقیق

پژوهش حاضر از رویکرد داده‌های پانلی^۱ نامتوازن^۲ استفاده می‌کند. این ساختار داده‌ای امکان رصد پویایی‌های زمانی و تغییرات مقطعی را به طور همزمان فراهم می‌آورد. مجموعه داده‌ها از ۳۲ رمزارز برتر و به صورت روزانه از تاریخ ۲۰۱۸/۰۱/۰۱ تا ۲۰۲۴/۱۲/۳۱ جمع‌آوری شده‌اند. این رویکرد به ویژه برای تحلیل بازارهای با نوسان بالا و غیرهمگن مانند رمزارزها، برتری دارد. که اسامی رمز ارزها در جدول ۱ به شرح زیر نمایش داده شده است:

جدول ۱. اسامی رمز ارزها

نام رمزارز	نماد	نام رمزارز	نماد
Bitcoin	BTC	Cosmos	ATOM
Ethereum	ETH	Tron	TRX
BNB	BNB	Stellar	XLM
Solana	SOL	EOS	EOS
Ripple	XRP	Zcash	ZEC
Cardano	ADA	Theta Network	THETA
Dogecoin	DOGE	Aave	AAVE
Compound	COMP	The Sandbox	SAND
Litecoin	LTC	Filecoin	FIL
Bitcoin Cash	BCH	Internet Computer	ICP
Uniswap	UNI	Near Protocol	NEAR
Polygon	MATIC	Ethereum Classic	ETC
Polkadot	DOT	Monero	XMR
Chainlink	LINK	VeChain	VET
Avalanche	AVAX	Hedera	HBAR
THORChain	RUNE	Decentraland	MANA

کوبین دسک؛ بیت کوبین دات کام؛ مجله خبری بیت کوبین

منبع

¹ Panel Data

² Unbalanced Panel

انتخاب این سی و دو رمزارز برای تحقیق حاضر بر اساس ملاحظات عملی و کاربردی صورت گرفته است که تضمین کننده قابلیت اجرا و کاربرپذیری نتایج در دنیای واقعی سرمایه‌گذاری است. نخستین معیار عملی، دسترسی به داده‌های قابل اعتماد بوده است؛ تمامی رمزارزهای انتخابی دارای سابقه معاملاتی مستمر در بزرگ‌ترین صرافی‌های جهانی مانند بایننس، کوین‌بیس و کراکن هستند و داده‌های قیمتی آن‌ها از طریق API های معتبر و پایگاه‌های داده استاندارد قابل دریافت می‌باشد. این موضوع به ویژه برای محققان و سرمایه‌گذارانی که قصد پیاده‌سازی مدل‌های قیمت‌گذاری و استراتژی‌های معاملاتی را دارند، اهمیت بسزایی دارد، زیرا امکان تکرارپذیری و آزمون مجدد نتایج را فراهم می‌آورد. دومین ملاحظه عملی، حجم معاملات و نقدشوندگی کافی است که امکان ورود و خروج سرمایه‌گذاران حقیقی و حقوقی را بدون تأثیر قابل توجه بر قیمت بازار میسر می‌سازد. رمزارزهای این فهرست به طور میانگین روزانه حجم معاملاتی بالایی دارند که این امر برای سرمایه‌گذاران نهادی و مدیران دارایی که با حجم‌های بزرگ سرمایه سروکار دارند، از اهمیت حیاتی برخوردار است. برای مثال، بیت‌کوین و اتریوم روزانه میلیاردها دلار حجم معاملات دارند که اجرای سفارش‌های بزرگ را بدون لغزش قیمتی قابل توجه ممکن می‌سازد. همچنین، این نمونه شامل دارایی‌هایی با طیف متنوعی از سطوح سرمایه‌بازار است؛ از دارایی‌های با ارزش بازار بالای صد میلیارد دلار (مانند BTC و ETH) تا دارایی‌های کوچک‌تر با سرمایه بازار چند میلیارد دلاری، که این تنوع امکان ارزیابی عملکرد استراتژی‌های معاملاتی در سبدهای سرمایه‌گذاری با ترکیب‌های مختلف ریسک و بازده را فراهم می‌آورد. سومین دلیل عملی، شناخت و پذیرش عمومی این رمزارزها در میان جامعه سرمایه‌گذاران است. تمامی دارایی‌های انتخابی در لیست صد رمزارز برتر از نظر ارزش بازار قرار دارند و برای اکثر سرمایه‌گذاران خرد و نهادی قابل شناسایی هستند. این شناخت عمومی نه تنها از دید روانشناسی بازار اهمیت دارد، بلکه از منظر عملی نیز به این معنی است که سرمایه‌گذاران می‌توانند به راحتی با این دارایی‌ها از طریق صرافی‌های معتبر و تحت نظارت قانونی معامله کنند. علاوه بر این، تنوع کاربردی در این فهرست به گونه‌ای طراحی شده که بازتابی از واقعیت بازار رمزارزها باشد؛ از دارایی‌های ذخیره ارزش بیت‌کوین گرفته تا پلتفرم‌های قراردادهای هوشمند سولنا² و اتریوم³، پروتکل‌های امور مالی غیرمتمرکز⁴، توکن‌های متاورس⁵ و حتی دارایی‌های مبتنی بر هیجان اجتماعی⁶. این تنوع کاربردی تضمین می‌کند که مدل قیمت‌گذاری و استراتژی معاملاتی توسعه یافته، قابلیت کاربرد در سبدهای سرمایه‌گذاری واقعی با اهداف متنوع را داشته باشد و نتایج تحقیق صرفاً محدود به یک دسته خاص از رمزارزها نگردد، بلکه قابل تعمیم به کل اکوسیستم دارایی‌های دیجیتال باشد.

بدین ترتیب، در این پژوهش روش‌های بررسی مدل به شرح موارد زیر خواهد بود:

مدل ترکیبی تحلیل پیش‌بینانه چند مرحله‌ای

مدل تحلیل پیش‌بینانه ترکیبی چندمرحله‌ای در گام اول خود از یک شیوه چندوجهی مبتنی بر اقتصادسنجی فضایی بهره می‌گیرد تا روابط ساختاری، وابستگی‌های فضایی - سلسله‌مراتبی و اثرات سرایت بین عوامل ریسک و بازده را در ساختار پیچیده بازار شناسایی و حذف کند. این لایه، شالوده تحلیل‌های بعدی مبتنی بر یادگیری عمیق را تشکیل می‌دهد.

مدل دوربین فضایی به عنوان هسته تحلیل فضایی این مدل ترکیبی عمل می‌کند، زیرا از یک سو اثرات فضایی متغیر وابسته (با ضریب همبستگی) و از سوی دیگر، اثرات فضایی تمامی متغیرهای توضیحی (با ضرایب) را در سراسر سلسله‌مراتب مدل‌سازی می‌کند. این ویژگی به مدل امکان می‌دهد تا مشخص کند که آیا تغییرات در عوامل ریسک در یک سطح (مانند سطح کلان) بر بازدهی یا ریسک در سطوح دیگر (مانند سطح شرکت) تأثیر می‌گذارد یا خیر. امتیاز اصلی این مدل، قابلیت تجزیه اثرات کل به سه جزء مجزا (اثر مستقیم، غیرمستقیم/سرایت و کل) با استفاده از روش لوساژ و پیس است. این تجزیه، اطلاعات حیاتی درباره کانال‌های انتقال شوک فراهم می‌کند. با برآورد این مدل و در نظر گرفتن اثرات ثابت زمانی باقیمانده‌هایی مدل را استخراج می‌کنیم که کاملاً برای اثرات فضایی و شوک‌های سیستمی تعدیل شده‌اند و آماده ورود به مدل‌های یادگیری عمیق هستند. از طرفی دیگر، مدل خودرگرسیون فضایی به عنوان یک مدل پایه و ابزار تأییدکننده، برای کمی‌سازی خالص و مستقیم اثرات سرایت بین عوامل ریسک و بازده در سطوح

¹ Bitcoin

² Solana

³ Ethereum

⁴ Uniswap, Aave, Compound

⁵ Decentral, The Sandbox

⁶ Dogecoin

سلسله‌مراتبی مورد استفاده قرار می‌گیرد. ضریب همبستگی فضایی در این مدل، قدرت و جهت این اثرات سرایت را نشان می‌دهد. ماتریس وزن فضایی که با ترکیب پویای فاصله سلسله‌مراتبی و همبستگی عوامل تعریف شده، ساختار روابط فضایی را مشخص می‌کند. برآورد این مدل برای هر دو متغیر بازدهی و ریسک در هر سطح سلسله‌مراتب انجام شده و آزمون‌های تشخیصی مانند آزمون I مورن برای تأیید معناداری وابستگی فضایی سلسله‌مراتبی به کار می‌روند تا از اعتبار ساختار فضایی در مدل دوربین فضایی اطمینان حاصل شود. در نهایت مدل برداری خودرگرسیون فضایی-زمانی تعمیم‌یافته یک شیوه چندمتغیره است که برای تحلیل پویایی‌های فضایی و زمانی به‌صورت همزمان و یکپارچه در ساختار مدل ترکیبی استفاده می‌شود. این مدل با در نظر گرفتن تأخیرهای زمانی خالص و تأخیرهای فضایی-زمانی، ابزار توانمندی برای تحلیل توابع واکنش آنی و تجزیه واریانس در ساختار چندسطحی فراهم می‌آورد. این تحلیل‌ها امکان ردیابی و کمی‌سازی مسیر و شدت انتقال شوک‌ها (مانند یک شوک نرخ بهره در سطح کلان) به سطوح پایین‌تر سلسله‌مراتب را فراهم کرده و تعیین می‌کنند که چه بخشی از نوسانات هر عامل در هر سطح ناشی از سرایت سطوح دیگر است. نتایج این مدل در درک ساختار ریسک سیستمی و اطلاع‌رسانی به راهبردهای پوشش ریسک در مراحل نهایی مدل ترکیبی حیاتی است.

جدول ۲. اندازه‌گیری و معرفی متغیرهای تحقیق

متغیر	(Symbol)	فرمول اندازه‌گیری و محاسبات دقیق	نقش تحلیلی و اهمیت متغیر در مدل‌سازی
بازدهی لگاریتمی	Rt	PClose,t تایید می‌شود. این مدل با در نظر گرفتن تأخیرهای زمانی خالص و تأخیرهای فضایی-زمانی، ابزار توانمندی برای تحلیل توابع واکنش آنی و تجزیه واریانس در ساختار چندسطحی فراهم می‌آورد. این تحلیل‌ها امکان ردیابی و کمی‌سازی مسیر و شدت انتقال شوک‌ها (مانند یک شوک نرخ بهره در سطح کلان) به سطوح پایین‌تر سلسله‌مراتب را فراهم کرده و تعیین می‌کنند که چه بخشی از نوسانات هر عامل در هر سطح ناشی از سرایت سطوح دیگر است. نتایج این مدل در درک ساختار ریسک سیستمی و اطلاع‌رسانی به راهبردهای پوشش ریسک در مراحل نهایی مدل ترکیبی حیاتی است.	نشانگر عملکرد سرمایه‌گذاری روزانه. این بازدهی به دلیل خاصیت جمعی بودن لگاریتمی، مناسب تحلیل‌های سری زمانی (مانند GARCH یا مدل‌های هوش مصنوعی) است و داده‌ها را ایستا می‌کند.
ریسک تاریخی (نوسان)	σR	R میانگین بازدهی در N روزه (مثلاً N=۳۰) است. این فرمول انحراف معیار بازدهی‌ها را در یک دوره متحرک محاسبه می‌کند.	مقیاس ریسک و عدم قطعیت. انحراف معیار بازدهی‌ها در یک بازه متحرک N روزه، میزان نوسان‌پذیری بازار را اندازه‌گیری می‌کند که یکی از متغیرهای کلیدی در مدل‌های مدیریت ریسک است.
شاخص قدرت نسبی (RSI)	RSI۱۴	RS نسبت میانگین متحرک نمایی (EMA) سودها به زیان‌ها در دوره ۱۴ روزه است. این شاخص مومنتوم و شرایط خرید/فروش افراطی را می‌سنجد.	سنجش مومنتوم (قدرت حرکت قیمت). این شاخص شدت تغییرات اخیر قیمت را ارزیابی می‌کند تا مشخص شود دارایی در شرایط خرید بیش از حد یا فروش بیش از حد قرار دارد.
میانگین متحرک نمایی (EMA)	EMA۱۲	Pt قیمت در زمان t و α ضریب هموارسازی برای دوره N (مثلاً N=۱۲) است. این فرمول به مشاهدات جدیدتر وزن بیشتری می‌دهد.	فیلترسازی سریع روند. به داده‌های اخیر وزن نمایی بیشتری می‌دهد. این کار باعث می‌شود EMA نسبت به میانگین ساده، تغییرات روند بازار را با تأخیر کمتری نشان دهد.
میانگین متحرک همگرا واگرا (MACD)	MACD	اختلاف بین دو میانگین متحرک نمایی (EMA) سریع (۱۲ دوره) و کند (۲۶ دوره). متغیری کلیدی برای تعیین جهت و قدرت روند.	شاخص تشخیص روند و مومنتوم. اختلاف بین دو EMA سریع و کند است. این شاخص برای شناسایی نقطه شروع و پایان روندها در معاملات استفاده می‌شود.
لگاریتم نرخ هش	ln(Hrate)	لگاریتم طبیعی داده خام نرخ هش روزانه (Hrate) برای تضمین ایستایی متغیر در تحلیل‌های رگرسیونی و سری‌های زمانی.	نمایانگر امنیت و سرمایه‌گذاری در شبکه. لگاریتم‌گیری برای ایستا کردن متغیر و وارد کردن آن به مدل‌های پیش‌بینی انجام می‌شود. نرخ هش بالا نشان‌دهنده اعتماد و سرمایه‌گذاری قوی در زیرساخت شبکه است.
نرخ تغییر سختی استخراج	ΔDt	نرخ تغییر روزانه سختی استخراج (Dt) (از این نرخ برای اندازه‌گیری شوک‌های ناگهانی در شبکه استفاده می‌شود).	اندازه‌گیری شوک عرضه/تقاضای ماینرها. نرخ تغییر سختی استخراج نشان می‌دهد که آیا ماینرهای جدیدی وارد شبکه شده‌اند (فشار عرضه) یا خارج شده‌اند، که بر پویایی عرضه رمزارز تأثیرگذار است.

میانگین متحرک ActiveM A	میانگین متحرک ساده (SMA) تعداد آدرس‌های فعال در پنجره N روزه (مثلاً N=۷) این محاسبه نویزهای روزانه را حذف و روند فعالیت را نشان می‌دهد.	$SMA_t = \frac{1}{N} \sum_{i=t-N+1}^t A_{actin}$	شاخص کاربرد و فعالیت شبکه. میانگین متحرک ساده، نویزهای روزانه را فیلتر کرده و روند پایدار استفاده واقعی و پذیرش شبکه توسط کاربران را نشان می‌دهد.
بازدهی شاخص RSP S&P ۵۰۰	بازدهی لگاریتمی روزانه شاخص (PSP) S&P\ ۵۰۰. برای سنجش پیوندها و سرایت ریسک بین بازارهای سنتی و رمزارز.	$R_{SP,t} = \ln \left(\frac{P_{SP,t}}{P_{SP,t-1}} \right)$	سنجش همبستگی با بازارهای سنتی. بازدهی لگاریتمی شاخص سهام آمریکا که برای بررسی سرایت ریسک (Contagion) و وابستگی قیمت رمزارز به جو کلی بازارهای مالی استفاده می‌شود.
بازدهی طلا RG	بازدهی لگاریتمی روزانه قیمت طلا (PG). برای بررسی نقش رمزارز به‌عنوان دارایی ذخیره ارزش (Safe- haven)	$R_{G,t} = \ln \left(\frac{P_{G,t}}{P_{G,t-1}} \right)$	سنجش نقش رمزارز به‌عنوان دارایی امن. بازدهی لگاریتمی قیمت طلا برای بررسی اینکه آیا رمزارز در زمان بحران‌های اقتصادی، مانند طلا، به‌عنوان دارایی ذخیره ارزش (Safe Haven) عمل می‌کند یا خیر.
میانگین متحرک احساسات SscoreMA	میانگین متحرک ساده (SMA) امتیاز احساسات خام (Sscore) در پنجره N روزه (مثلاً N=۷). این محاسبه روند غالب هیجانات را از داده‌های شبکه‌های اجتماعی استخراج می‌کند.	$S_{score}^{MA} = \frac{1}{N} \sum_{i=t-N+1}^t S_{score}$	شاخص روند هیجانات بازار. میانگین متحرک نوسانات شدید احساسات روزانه را صاف کرده و روند غالب خوش‌بینی یا بدبینی جمعی را که بر تصمیمات معاملاتی اثر می‌گذارد، نشان می‌دهد.
نرخ تغییر هفتگی جستجو ΔTs	نرخ تغییر هفتگی شاخص جستجوی گوگل (Ts). برای نشان دادن شوک تقاضا یا تغییرات سریع در علاقه عمومی.	$\Delta Ts = \frac{T_{s,t} - T_{s,t-7}}{T_{s,t-7}}$	اندازه‌گیری شوک علاقه عمومی. نرخ تغییر هفتگی شاخص جستجوی گوگل نشان‌دهنده تغییر ناگهانی در توجه و تقاضای خرده‌فروشان است که می‌تواند پیشگوی (Leading Indicator) تغییرات قیمت باشد.
منابع دانلود داده https://developers.binance.com/docs/binance-spot-api-docs/rest-api ; https://www.blockchain.com/explorer/api ; Scan-Based Trading; https://academy.santiment.net/#api ; https://finance.yahoo.com/lookup ; https://lunarcrush.com/developers/docs			

شبکه عصبی کانولوشنی-حافظه بلندمدت کوتاه‌مدت با مکانیزم توجه^۱

معماری CNN-LSTM با مکانیزم توجه که در معادلات (۷) تا (۱۷) شرح داده شده است، یک مدل یادگیری عمیق پیشرفته است که برای استخراج و مدل‌سازی الگوهای پیچیده غیرخطی در داده‌های سری زمانی طراحی شده است. این معماری از سه بخش اصلی تشکیل شده است: لایه کانولوشن یک‌بعدی که با استفاده از فیلترهای کانولوشنی، ویژگی‌های محلی و الگوهای کوتاه‌مدت را از پنجره‌های متوالی داده‌ها استخراج می‌کند؛ لایه LSTM که با استفاده از ساختار دروازه‌ای پیچیده (دروازه فراموشی، ورودی، و خروجی)، وابستگی‌های بلندمدت را یاد می‌گیرد و مشکل محو شدن گرادینت^۲ در شبکه‌های عصبی بازگشتی ساده را حل می‌کند؛ و مکانیزم توجه که به مدل امکان می‌دهد به‌صورت پویا بر مهم‌ترین بخش‌های توالی ورودی تمرکز کند و وزن بیشتری به اطلاعات مرتبط‌تر اختصاص دهد. مکانیزم توجه با محاسبه امتیازهای توجه^۳ که در معادلات (۱۰) و (۱۱) نشان داده شده، به‌صورت تطبیقی تعیین می‌کند که کدام بخش‌های حالت‌های پنهان LSTM برای پیش‌بینی خروجی نهایی بیشترین اهمیت را دارند. این ویژگی به‌خصوص در بازارهای مالی که ممکن است برخی رویدادها یا دوره‌های زمانی تأثیر بسیار بیشتری نسبت به سایرین داشته باشند (مانند اعلان‌های مهم، شوک‌های بازار، یا نقاط چرخش)، بسیار ارزشمند است. در این تحقیق، ورودی این معماری شامل نه تنها متغیرهای اصلی (فنی، زنجیره‌ای، احساسات، و کلان) بلکه باقیمانده‌های مدل SDM و اثرات فضایی آن‌ها نیز هست که این رویکرد هیبریدی (معادله ۱۸) را شکل می‌دهد. این ترکیب امکان می‌دهد که مدل هم از ساختار خطی و قابل تفسیر مدل اقتصادسنجی فضایی بهره‌بردار و هم

¹ CNN-LSTM-Attention

² vanishing gradient

³ attention scores

الگوهای غیرخطی پیچیده‌ای که مدل‌های خطی نمی‌توانند شناسایی کنند را کشف کند. برای جلوگیری از بیش‌برازش^۱، از تکنیک‌های منظم‌سازی متعددی شامل^۲ (با نرخ ۰.۳ تا ۰.۵)، برای تثبیت فرایند آموزش^۳، با نظارت بر خطای اعتبارسنجی، و L_2 regularization برای وزن‌های شبکه استفاده می‌شود.

شبکه عصبی گرافی^۴

شبکه عصبی گرافی یک رویکرد نوین یادگیری عمیق است که به‌طور خاص برای کار با داده‌های ساختاریافته به‌صورت گراف طراحی شده است و می‌تواند روابط پیچیده و غیریکنواخت بین نودها (در اینجا رمزارزها) را به‌صورت مستقیم مدل‌سازی کند. در بافت این تحقیق، بازار رمزارزها به‌عنوان یک گراف دینامیک در نظر گرفته می‌شود که در آن هر رمزارز یک نود و روابط بین آن‌ها (مانند همبستگی، مشابهت تکنولوژیکی، یا روابط تجاری) یال‌های گراف را تشکیل می‌دهند. GNN با استفاده از عملیات انتشار پیام^۵ و تجمع^۶، به هر نود امکان می‌دهد که اطلاعات از همسایگان خود جمع‌آوری کند و نمایش یادگیری شده خود را به‌روز کند. این فرایند در چندین لایه تکرار می‌شود تا اطلاعات از همسایه‌های دورتر نیز منتشر شود و هر نود دیدگاه جامع‌تری از ساختار کلی شبکه به‌دست آورد. یکی از مزایای برجسته GNN نسبت به روش‌های سنتی این است که می‌تواند ساختارهای غیریکنواخت و ناهمگن را مدیریت کند و نیازی به فرض همگنی فضایی ندارد - بر خلاف مدل‌های اقتصادسنجی فضایی که معمولاً فرض می‌کنند تمام رمزارزها به‌صورت یکسان تحت تأثیر همسایگان خود قرار می‌گیرند. در این پژوهش، از معماری‌های مختلف شبکه عصبی گرافی و شبکه کانولوشنی گرافی که قابلیت یادگیری وزن‌های توجه بین نودها را دارد، استفاده می‌شود. ماتریس وزن فضایی پویا (W_t) که در معادله (۳) تعریف شده، به عنوان ماتریس مجاورت^۷ گراف در نظر گرفته می‌شود و ساختار روابط را مشخص می‌کند. ویژگی‌های نود^۸ شامل متغیرهای فنی، زنجیره‌ای، و سایر مشخصات هر رمزارز هستند. مدل GNN به‌صورت end-to-end آموزش داده می‌شود و خروجی آن پیش‌بینی‌هایی برای بازدهی یا نوسان هر رمزارز با در نظر گرفتن اطلاعات کل شبکه است. این مدل یکی از چهار مدل پایه در سیستم یادگیری گروهی (معادلات ۲۰ و ۲۱) است و دیدگاه منحصر به فردی درباره ساختار شبکه و روابط بین رمزارزها فراهم می‌آورد.

مدل ترنسفورمر^۹

مدل ترنسفورمر که ابتدا برای وظایف پردازش زبان طبیعی توسعه یافت، اکنون به‌طور فزاینده‌ای در حوزه پیش‌بینی سری‌های زمانی مالی نیز مورد استفاده قرار می‌گیرد. معماری اصلی ترنسفورمر بر اساس مکانیزم توجه چند سری^{۱۰} است که امکان مدل‌سازی وابستگی‌های بلندمدت و پیچیده را بدون نیاز به پردازش متوالی (که در مدل‌های RNN و LSTM ضروری است) فراهم می‌آورد. این ویژگی باعث می‌شود که ترنسفورمر بتواند به‌طور موازی آموزش ببیند و سرعت یادگیری را به‌طور قابل توجهی افزایش دهد. مکانیزم توجه در ترنسفورمر به مدل اجازه می‌دهد که به‌صورت پویا روابط بین تمام جفت‌های زمانی در توالی را یاد بگیرد و تعیین کند که کدام بخش‌های گذشته برای پیش‌بینی آینده بیشترین اهمیت را دارند، بدون اینکه محدودیت فاصله زمانی داشته باشد. در این تحقیق، از نسخه اصلاح‌شده ترنسفورمر برای سری‌های زمانی استفاده می‌شود که شامل کدگذاری موقعیتی^{۱۱} برای حفظ اطلاعات ترتیب زمانی، لایه‌های توجه چندسری برای کشف روابط پیچیده بین دوره‌های مختلف زمانی و بین متغیرهای مختلف (توجه چندمتغیره)، و شبکه‌های پیشخور^{۱۲} برای تبدیلات غیرخطی است. یکی از نوآوری‌های این تحقیق، ترکیب اطلاعات فضایی در معماری ترنسفورمر است که به مدل امکان می‌دهد تنها الگوهای زمانی بلکه روابط بین رمزارزها را نیز یاد بگیرد. برای این منظور، اطلاعات همسایگی فضایی (از ماتریس W_t) به عنوان ویژگی‌های اضافی یا از طریق ماسک توجه^{۱۳} به مدل معرفی می‌شوند.

¹ overfitting

² Dropout

³ Early Stopping

⁴ Graph Neural Network - GNN

⁵ message passing

⁶ aggregation

⁷ adjacency matrix

⁸ node features

⁹ Transformer Model

¹⁰ multi-head attention

¹¹ positional encoding

¹² feedforward networks

¹³ attention mask

مدل ترنسفورمر نیز به عنوان یکی از چهار مدل پایه در سیستم یادگیری گروهی قرار می‌گیرد و با توانایی یادگیری الگوهای بلندمدت و پیچیده، تنوع و قدرت پیش‌بینی سیستم ترکیبی را افزایش می‌دهد. آموزش این مدل با استفاده از تکنیک‌های منظم‌سازی مشابه^۱ و بهینه‌سازی با Adam انجام می‌شود.

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک مدل محاسباتی الهام گرفته از ساختار مغز انسان است که از تعداد زیادی واحد پردازشی (نورون) تشکیل شده است که به صورت لایه‌ای به یکدیگر متصل هستند. هر نورون، ورودی‌های دریافتی را با وزن‌های مشخص ترکیب کرده و پس از اعمال یک تابع فعال‌سازی غیرخطی، یک خروجی تولید می‌کند. یادگیری در این شبکه‌ها از طریق تنظیم این وزن‌ها با استفاده از الگوریتم‌هایی مانند پس‌انتشار خطا انجام می‌شود، به طوری که خطای پیش‌بینی به حداقل برسد. این شبکه‌ها به دلیل توانایی ذاتی در یادگیری روابط پیچیده و غیرخطی بین متغیرهای ورودی (مانند داده‌های فنی، زنجیره‌ای و کلان) و متغیر هدف (مانند بازدهی یا نوسان رمزارز)، پایه و اساس تمامی معماری‌های پیچیده‌تر یادگیری عمیق را در این پژوهش تشکیل می‌دهند.

شبکه عصبی مخچه

شبکه عصبی مخچه در حوزه علوم اعصاب محاسباتی و مدل‌سازی سیستم‌های بیولوژیکی کاربرد دارد و مستقیماً به الگوریتم‌های رایج پیش‌بینی سری‌های زمانی در بازارهای مالی مربوط نمی‌شود؛ با این حال، می‌توان آن را به عنوان یک ساختار کنترلی با قابلیت یادگیری سریع در نظر گرفت. در زمینه محاسبات، این شبکه معمولاً به شبکه‌هایی اشاره دارد که دارای یک ساختار کنترلی دقیق برای هماهنگی حرکات و مدیریت تعادل هستند. در حوزه یادگیری ماشین، می‌توان از این مفهوم برای توسعه مکانیزم‌هایی استفاده کرد که وظیفه بهینه‌سازی و تثبیت خروجی‌های مدل‌های اصلی را بر عهده دارند. در مدل‌های پیش‌بینی، یک سامانه کنترلی مشابه مخچه می‌تواند برای تنظیم نهایی وزن‌های مدل‌های گروهی یا در چارچوب یادگیری تقویتی برای اطمینان از تصمیم‌گیری‌های معاملاتی پایدار و بدون خطاهای بزرگ استفاده شود.

یادگیری عمیق

یادگیری عمیق زیرشاخه‌ای از یادگیری ماشین و شبکه‌های عصبی مصنوعی است که از شبکه‌هایی با تعداد زیادی لایه پنهان (معمولاً بیش از سه لایه) استفاده می‌کند تا نمایش‌های سلسله‌مراتبی و انتزاعی از داده‌ها را به طور خودکار بیاموزد. در بازارهای مالی، مزیت کلیدی یادگیری عمیق این است که می‌تواند ویژگی‌های پیچیده را مستقیماً از داده‌های خام (مانند الگوهای پیچیده قیمتی یا الگوهای ترافیک زنجیره‌ای) بدون نیاز به مهندسی دستی ویژگی‌ها استخراج کند. در این پژوهش، از معماری‌های عمیقی چون شبکه کانولوشنی-حافظه بلندمدت کوتاه‌مدت، شبکه عصبی گرافی و مدل ترنسفورمر استفاده شده است که هر کدام برای استخراج انواع خاصی از الگوها—مانند وابستگی‌های زمانی بلندمدت، روابط شبکه‌ای فضایی، یا ارتباطات پیچیده دوربرد—طراحی شده‌اند تا ناهنجاری‌های غیرخطی باقیمانده از مدل‌های اقتصادسنجی فضایی را به دقت مدل‌سازی و پیش‌بینی کنند.

رویکرد هیبریدی اقتصادسنجی فضایی-یادگیری عمیق

رویکرد هیبریدی که در معادلات (۱۸) و (۱۹) فرمول‌بندی شده است، نوآوری اصلی این تحقیق را تشکیل می‌دهد و سعی دارد مزایای دو دنیای متفاوت - مدل‌سازی اقتصادسنجی ساختاری و یادگیری عمیق - را در یک چارچوب یکپارچه ترکیب کند. این رویکرد از این فرض بنیادین شروع می‌کند که رفتار بازارهای مالی، به‌ویژه بازار پیچیده و نوظهور رمزارزها، ترکیبی از روابط خطی ساختاری (که توسط نظریه‌های اقتصادی و مالی قابل توضیح و تفسیر هستند) و الگوهای غیرخطی پیچیده (که ناشی از رفتارهای غیرمنطقی سرمایه‌گذاران، فیدبک‌های مثبت و منفی، تعاملات پیچیده بین متغیرها، و پویایی‌های آشوبی بازار هستند) است. در مرحله اول، مدل دوربین فضایی برای شناسایی و برآورد روابط خطی بین متغیرها و اثرات فضایی مستقیم و غیرمستقیم آن‌ها استفاده می‌شود که نتایج آن قابلیت تفسیر اقتصادی بالایی دارد و می‌تواند به پرسش‌هایی مانند "افزایش یک درصدی در نرخ هش بیت‌کوین چه تأثیری بر بازدهی خود آن و سایر رمزارزها دارد؟" پاسخ دهد. سپس، باقیمانده‌های این مدل ($\epsilon_{i,t}$) که شامل اطلاعاتی است که مدل خطی نتوانسته کشف کند - از جمله غیرخطی بودن‌ها، تعاملات مرتبه بالا، رژیم‌های متفاوت بازار، و اثرات آستانه‌ای - همراه با متغیرهای اصلی و وقفه‌های فضایی باقیمانده‌ها (که اطلاعات

¹ Dropout, Layer Normalization

مربوط به شوک‌های مشترک یا سرریزهای غیرخطی بین رمزارزها را حمل می‌کنند) به عنوان ورودی به معماری CNN-LSTM-Attention داده می‌شوند. این معماری یادگیری عمیق با توانایی استخراج ویژگی‌های انتزاعی و یادگیری الگوهای پیچیده از داده‌ها، می‌تواند ساختارهای غیرخطی پنهان در باقیمانده‌ها را کشف و مدل‌سازی کند. خروجی نهایی مدل (معادله ۱۹) ترکیب خطی از پیش‌بینی مدل اقتصادسنجی (که جزء ساختاری و قابل تفسیر است) و پیش‌بینی مدل یادگیری عمیق (که جزء غیرخطی و تطبیقی است) است که وزن‌های آن‌ها (۷) از طریق فرایند آموزش بهینه می‌شوند. این رویکرد دو مزیت عمده دارد: اول، با استفاده از ساختار مدل اقتصادسنجی، قابلیت تفسیرپذیری حفظ می‌شود و محققان می‌توانند روابط علی و اثرات فضایی را به‌صورت شفاف تحلیل کنند؛ دوم، با بهره‌گیری از قدرت مدل‌سازی مدل‌های یادگیری عمیق، دقت پیش‌بینی به‌ویژه در شرایط پیچیده و نامنظم بازار به‌طور قابل‌توجهی افزایش می‌یابد. این رویکرد به‌ویژه در بازار رمزارزها که هم تحت تأثیر عوامل بنیادی قابل تفسیر (مانند فعالیت زنجیره‌ای و احساسات) و هم رفتارهای پیچیده غیرخطی (مانند حباب‌ها، ترس و طمع جمعی، و اثرات رسانه‌های اجتماعی) قرار دارد، بسیار مناسب است. که در این پژوهش مورد استفاده قرار می‌گیرد.

یافته‌ها

تحلیل آمارهای توصیفی (جدول ۳)، ماهیت پیچیده، ناهمگون و غیرخطی مجموعه داده‌های مورد استفاده در این پژوهش را که با هدف «تحلیل مقایسه‌ای رفتار بازار رمزارز در ایران و آمریکا» طراحی شده، به وضوح تأیید می‌کند. این مجموعه داده‌ها، به دلیل ماهیت پژوهش، شامل ترکیبی از سه نوع متغیر کاملاً متفاوت است: ۱. شاخص‌های فنی و قیمتی (مانند میانگین‌های متحرک و شاخص‌های نسبی)، ۲. معیارهای فعالیت درون‌زنجیره‌ای و اجتماعی و ۳. عوامل کلان اقتصادی مربوط به دو محیط متضاد (بازار توسعه‌یافته آمریکا و بازار تورم‌زده ایران). این ترکیب، باعث ایجاد ناهمگونی شدید در مقیاس متغیرها می‌شود؛ به‌طوری که متغیرهای مطلق (مانند سطح قیمتی) مقیاسی بسیار متفاوت با متغیرهای نسبی (مانند بازدهی‌ها و نرخ‌های تغییر) دارند. مهم‌تر از آن، بررسی شاخص‌های توزیع آماری، به‌ویژه کشیدگی، نشان‌دهنده غیرنرمال بودن قاطع توزیع بازدهی‌ها است. این امر حاکی از وجود دمه‌های ضخیم و وقوع مکرر نوسانات شدید و جهش‌های قیمتی بزرگ در بازار رمزارز و شاخص‌های کلان است. همچنین، وجود چولگی در توزیع برخی متغیرها، نشان‌دهنده عدم تقارن در ریسک و بازده است. این ویژگی‌های آماری نامطلوب شامل ناهمگونی، غیرنرمال بودن توزیع و نوسانات شدید استفاده از مدل‌های خطی و سنتی اقتصادسنجی را برای تحلیل مقایسه‌ای دو بازار با پویایی‌های متفاوت (نظیر ایران و آمریکا) نامناسب می‌سازد. در نتیجه، انتخاب مدل‌های هیبریدی یادگیری عمیق (مانند ترکیب شبکه‌های عصبی کانولوشنی و حافظه بلندمدت کوتاه مدت) به دلیل توانایی ذاتی آن‌ها در مدل‌سازی دقیق روابط غیرخطی، جذب الگوهای پیچیده قیمتی و مدیریت خوشه‌بندی نوسانات، برای دستیابی به یک تحلیل جامع و استخراج یک استراتژی معاملاتی بومی، امری ضروری و موجه است.

جدول ۳. آمار توصیفی

متغیر	نماد	میانگین	انحراف معیار	حداقل	حداکثر	چولگی	کشیدگی
بازدهی رمزارز	Rt	۰.۰۰۰۷	۰.۰۴۰۱	-۰.۴۵۶۶	۰.۵۲۱۸	۰.۰۹۸۴	۱۱.۱۹۲۳
نوسان‌پذیری	σR	۰.۰۴	۰.۰۱۶۳	۰.۰۱۳۵	۰.۱۱۷۲	۰.۹۹۹۷	۱.۱۰۹۵
شاخص قدرت نسبی	RSI۱۴	۵۰.۰۸۱۸	۱۱.۵۱۷۳	۱۱.۳۳۲۳	۹۰.۶۲۷۷	۰.۰۰۱۹	-۰.۲۷۹۸
میانگین متحرک نمایی	EMA۱۲	۱۰.۷۹۸.۸۲	۹.۸۴۲.۱۰	۲.۷۵۷.۸۸	۵۹.۹۶۳.۳۰	۱.۵۴۳۴	۲.۱۲۶۴
مکدی	MACD	۶۳.۸۵۶۹	۸۰۸.۳۸۴۶	-۵.۷۲۱.۲۲	۳.۹۲۴.۹۷	-۰.۱۹۹	۱۲.۳۳۹۱
لگاریتم نرخ هش	ln_H_rate	۱۶.۴۸۸۳	۱.۰۵۶	۱۴.۷۹۱۸	۱۸.۰۶۷۳	۰.۱۶۰۱	-۰.۹۹۶۱
نرخ تغییر سختی استخراج	ΔDt	۰.۰۰۶۹	۰.۰۰۷۱	-۰.۰۱۷۱	۰.۰۴۶	۰.۳۵۵۱	۰.۱۳۳۲
میانگین متحرک آدرس‌های فعال	A_active_MA	۱.۹۵۶۷	۰.۲۸۰۱	۱.۳۴۰۲	۲.۷۶۸۶	۰.۰۳۳۶	-۰.۵۷۰۱
بازدهی S&P	RSP	۰.۰۰۰۳	۰.۰۱۲۵	-۰.۱۰۹۴	۰.۰۹۱۱	-۰.۵۵۱۶	۱۵.۱۵۰۶
بازدهی طلا	RG	۰.۰۰۰۳	۰.۰۱۰۱	-۰.۰۵۳۸	۰.۰۵۰۴	-۰.۰۶۷۸	۴.۳۸۱۳
بازدهی بازار داخلی ایران	RIRR	۰.۰۰۰۷	۰.۰۰۷۶	-۰.۰۲۴۵	۰.۰۵۰۹	۰.۲۲۸۸	۱.۷۶۱
میانگین متحرک احساسات	Sscore_MA	۵۱.۵۲۷۳	۶۸۳۲۹	۳۶.۱۷۷	۶۹.۹۶۷۸	-۰.۱۱۹۷	-۰.۳۶۰۱
نرخ تغییر جستجوی گوگل	ΔTs	-۰.۰۰۰۰۴	۰.۰۵۷۳	-۰.۲۳۹۳	۰.۲۲۴۱	-۰.۰۵۷۸	۰.۲۹۲۹

جدول ۳ نشان‌دهنده آمار توصیفی متغیرهای مختلف مورد استفاده در تحلیل مقایسه‌ای بازار رمزارز در ایران و آمریکاست. از نظر توزیع آماری، بازدهی رمزارز با کشیدگی ۱۱.۱۹۲۳ به وضوح از توزیع نرمال فاصله دارد و نشان‌دهنده دمه‌های ضخیم و وقوع مکرر نوسانات شدید در این بازار است. مشابه همین الگو در شاخص MACD با کشیدگی ۱۲.۳۳۹۱ و بازدهی S&P با کشیدگی ۱۵.۱۵۰۶ نیز مشاهده می‌شود. از نظر چولگی، اکثر متغیرها چولگی نزدیک به صفر دارند، اما برخی متغیرها مانند میانگین متحرک نمایی (EMA۱۲) با چولگی ۱.۵۴۳۴ و بازدهی S&P با چولگی منفی ۰.۵۵۱۶، عدم تقارن قابل توجهی را نشان می‌دهند. ناهمگونی مقیاس‌ها نیز کاملاً مشهود است؛ برای مثال، میانگین متحرک نمایی (EMA۱۲) با میانگین ۱۰.۷۹۸۸۲ و انحراف معیار ۹.۸۴۲۱۰ در مقایسه با متغیرهای نسبی مانند بازدهی‌ها که معمولاً میانگینی نزدیک به صفر دارند، در مقیاسی کاملاً متفاوت قرار دارد. محدوده تغییرات متغیرها نیز بینش‌های مهمی ارائه می‌دهد. بازدهی رمزارز از حداقل ۰.۴۵۶۶- تا حداکثر ۰.۵۲۱۸ نوسان داشته که نشان‌دهنده نوسانات شدید قیمتی در یک روز است. شاخص‌های تکنیکال مانند RSI با محدوده ۱۱.۳۳ تا ۹۰.۶۳، طیف وسیعی از شرایط بازار از فروش شدید تا خرید شدید را پوشش می‌دهد. مقایسه بازدهی بازارهای مختلف نیز قابل توجه است؛ بازدهی رمزارز با میانگین ۰.۰۰۰۷ و انحراف معیار ۰.۰۰۴۰۱، نوسان بسیار بیشتری نسبت به بازدهی S&P (انحراف معیار ۰.۰۰۱۲۵) و بازار داخلی ایران (انحراف معیار ۰.۰۰۰۷۶) نشان می‌دهد. این ناهمگونی در توزیع‌ها، عدم تقارن در ریسک و بازده، و وجود رفتارهای غیرخطی و نوسانات شدید، همگی بر ضرورت استفاده از مدل‌های پیشرفته یادگیری عمیق به جای روش‌های خطی سنتی تأکید می‌کند، زیرا این مدل‌ها توانایی بیشتری در کشف و استخراج الگوهای پیچیده و غیرخطی موجود در داده‌ها دارند.

جدول ۴: نتایج تخمین مدل دوربین فضایی دوگانه (SDM)

متغیر	ایران - ضریب	ایران t-stat	ایران p-value	آمریکا - ضریب	آمریکا t-stat	آمریکا p-value
متغیرهای وابسته فضایی (p)						
اثر سرریز فضایی (p)	۰.۳۴۲***	۸.۶۷	۰.۰۰۰	۰.۴۵۶***	۱۲.۳۴	۰.۰۰۰
متغیرهای فنی						
RSI۱۴	۰.۰۱۲۸**	۲.۴۵	۰.۰۱۴	۰.۰۲۴۵***	۴.۸۹	۰.۰۰۰
EMA۱۲	۰.۰۰۶۷*	۱.۸۹	۰.۰۵۹	۰.۰۱۳۴***	۳.۶۷	۰.۰۰۰
MACD	۰.۰۰۸۹**	۲.۱۳	۰.۰۳۳	۰.۰۱۷۸***	۴.۲۳	۰.۰۰۰
متغیرهای زنجیره‌ای						
ln(Hash Rate)	۰.۰۴۵۶***	۵.۲۳	۰.۰۰۰	۰.۰۷۱۲***	۸.۴۵	۰.۰۰۰
ΔDifficulty	۰.۰۲۳۴***	۲.۸۹	۰.۰۰۴	۰.۰۳۸۹***	۴.۶۷	۰.۰۰۰
Active Addresses	۰.۰۳۱۲***	۳.۹۸	۰.۰۰۰	۰.۰۵۲۳***	۶.۷۸	۰.۰۰۰
متغیرهای احساسات						
Sentiment Score	۰.۰۱۸۹**	۲.۶۷	۰.۰۰۸	۰.۰۲۹۸***	۴.۴۵	۰.۰۰۰
ΔGoogle Trends	۰.۰۱۴۵*	۱.۹۲	۰.۰۵۵	۰.۰۲۶۷***	۳.۸۹	۰.۰۰۰
متغیرهای کلان						
R(S&P ۵۰۰)	۰.۱۲۳۴***	۲.۷۸	۰.۰۰۵	۰.۲۴۵۶***	۶.۸۹	۰.۰۰۰
R(Gold)	۰.۰۷۸۹*	۱.۹۸	۰.۰۴۸	۰.۱۲۳۴***	۳.۶۷	۰.۰۰۰
متغیرهای خاص ایران						
ER(real)	۰.۱۵۶۷***	۴.۲۳	۰.۰۰۰	-	-	-
Δπ تورم	۰.۰۹۳۴***	۲.۵۶	۰.۰۱۰	-	-	-
EUP(IR)	۰.۰۶۷۸**	۲.۳۴	۰.۰۱۹	-	-	-
اثرات فضایی متغیرها (W×X)						
W×RSI۱۴	۰.۰۰۹۸*	۱.۸۷	۰.۰۶۲	۰.۰۱۸۹***	۳.۴۵	۰.۰۰۱
W×Hash Rate	۰.۰۲۳۴***	۲.۴۵	۰.۰۱۴	۰.۰۴۴۵***	۵.۲۳	۰.۰۰۰
W×Sentiment	۰.۰۱۵۶*	۱.۹۵	۰.۰۵۱	۰.۰۲۸۹***	۴.۱۲	۰.۰۰۰
آماره‌های مدل						
R ²	۰.۶۲۳۴	-	-	۰.۷۴۵۶	-	-
Log-Likelihood	۲۸۴۵.۳۴	-	-	۳۵۶۷.۸۹	-	-
AIC	-۵۶۳۴.۶۸	-	-	-۷۰۸۹.۷۸	-	-
Moran's I	۰.۰۲۳۴	۲.۸۹	۰.۰۰۴	۰.۰۰۸۹	۱.۲۳	۰.۲۱۹

***p<۰.۰۱, **p<۰.۰۵, *p<۰.۱

جدول چهارم نتایج تخمین مدل دوربین فضایی دوگانه برای بازارهای ایران و آمریکا را نشان می‌دهد. این مدل اثرات سرریز فضایی قابل توجهی را در هر دو بازار آشکار کرده است. ضریب سرریز فضایی (رو) در بازار آمریکا با مقدار حدود ۰.۴۵ بیشتر از بازار ایران با مقدار ۰.۳۴ است که نشان‌دهنده همبستگی فضایی قوی‌تر در بازار آمریکا می‌باشد. همچنین تمامی شاخص‌های فنی (مانند شاخص قدرت نسبی، میانگین متحرک نمایی و شاخص همگرایی-واگرایی میانگین متحرک) در بازار آمریکا ضرایب بزرگتر و معنادارتری دارند. متغیرهای زنجیره‌ای شامل نرخ هش، سختی شبکه و آدرس‌های فعال در هر دو بازار معنادار هستند اما تأثیر آن‌ها در آمریکا حدود ۶۰ تا ۷۰ درصد بیشتر است. در بخش متغیرهای خاص ایران، نرخ ارز واقعی با ضریب ۰.۱۵ بیشترین تأثیر را دارد که نشان‌دهنده اهمیت بالای نوسانات ارزی در بازار رمزارز ایران است. ضرایب اثرات فضایی متغیرها نیز برای آمریکا بزرگتر است که نشان می‌دهد اثرات سرریز در این بازار قوی‌تر عمل می‌کند. شاخص‌های نیکویی برازش حاکی از عملکرد بهتر مدل در بازار آمریکا است، به طوری که ضریب تعیین در آمریکا ۰.۷۴ و در ایران ۰.۶۲ می‌باشد. آزمون موران‌ای نیز وجود خودهمبستگی فضایی باقیمانده معنادار در مدل ایران را تأیید می‌کند، در حالی که در مدل آمریکا این خودهمبستگی به خوبی کنترل شده است. این نتایج نشان می‌دهد بازار آمریکا ساختار منسجم‌تری دارد و تأثیرپذیری آن از شاخص‌های تکنیکال و زنجیره‌ای بیشتر است.

جدول ۵: تجزیه اثرات مستقیم، غیرمستقیم و کل (SDM)

متغیر	ایران - مستقیم	ایران - غیرمستقیم	ایران - کل	آمریکا - مستقیم	آمریکا - غیرمستقیم	آمریکا - کل
متغیرهای فنی						
RSI۱۴	۰.۰۱۳۴***	۰.۰۰۷۶*	۰.۰۲۱۰***	۰.۰۲۵۶***	۰.۰۱۲۳**	۰.۰۳۷۹***
EMA۱۲	۰.۰۰۷۱*	۰.۰۰۳۹	۰.۰۱۱۰*	۰.۰۱۴۰***	۰.۰۰۷۸**	۰.۰۲۱۸***
MACD	۰.۰۰۹۳***	۰.۰۰۴۸*	۰.۰۱۴۱***	۰.۰۱۸۶***	۰.۰۱۰۲**	۰.۰۲۸۸***
متغیرهای زنجیره‌ای						
ln(Hash Rate)	۰.۰۴۷۸***	۰.۰۱۸۹**	۰.۰۶۶۷***	۰.۰۷۴۵***	۰.۰۳۴۵***	۰.۱۰۹۰***
Δ Difficulty	۰.۰۲۴۵***	۰.۰۱۱۲*	۰.۰۳۵۷***	۰.۰۴۰۷***	۰.۰۱۹۸**	۰.۰۶۰۵***
Active Addresses	۰.۰۳۲۶***	۰.۰۱۴۵**	۰.۰۴۷۱***	۰.۰۵۴۷***	۰.۰۲۶۷***	۰.۰۸۱۴***
متغیرهای احساسات						
Sentiment Score	۰.۰۱۹۸**	۰.۰۰۸۹*	۰.۰۲۸۷**	۰.۰۳۱۲***	۰.۰۱۵۶**	۰.۰۴۶۸***
Δ Google Trends	۰.۰۱۵۲*	۰.۰۰۶۸	۰.۰۲۲۰*	۰.۰۲۷۹***	۰.۰۱۳۴**	۰.۰۴۱۳***
متغیرهای کلان						
R(S&P ۵۰۰)	۰.۱۲۸۹***	۰.۰۵۶۷*	۰.۱۸۵۶***	۰.۲۵۶۷***	۰.۱۲۳۴***	۰.۳۸۰۱***
R(Gold)	۰.۰۸۲۵*	۰.۰۳۷۸	۰.۱۲۰۳*	۰.۱۲۸۹***	۰.۰۶۲۳**	۰.۱۹۱۲***
متغیرهای خاص ایران						
ER(real)	۰.۱۶۳۸***	۰.۰۷۲۳**	۰.۲۳۶۱***			
$\Delta\pi$ (تورم)	۰.۰۹۷۷**	۰.۰۴۳۲*	۰.۱۴۰۹**			

جدول پنجم نتایج تجزیه اثرات در مدل فضایی را به اثرات مستقیم، غیرمستقیم و کل نشان می‌دهد. در هر دو بازار ایران و آمریکا، اثرات مستقیم به مراتب بزرگتر از اثرات غیرمستقیم هستند. برای متغیرهای فنی، اثرات کل در بازار آمریکا تقریباً دو برابر ایران است. به عنوان مثال، اثر کل شاخص قدرت نسبی در آمریکا ۰.۰۳۷ و در ایران ۰.۰۲۱ محاسبه شده است. در میان متغیرهای زنجیره‌ای، نرخ هش بیشترین تأثیر را دارد که اثر کل آن در آمریکا ۰.۱۰۹ و در ایران ۰.۰۶۶ است. اثرات غیرمستقیم در آمریکا عموماً معنادارتر از ایران هستند که نشان‌دهنده سرریز قوی‌تر اطلاعات در این بازار است. متغیرهای کلان اقتصادی مانند بازده شاخص اس اند پی و طلا تأثیر قابل توجهی در هر دو بازار دارند، اما این تأثیر در آمریکا حدود دو برابر ایران است. متغیرهای خاص ایران شامل نرخ ارز واقعی با اثر کل ۰.۲۳۶ و تورم با اثر کل ۰.۱۴ نقش پررنگی در بازار رمزارز ایران ایفا می‌کنند. این یافته‌ها نشان می‌دهد سرمایه‌گذاران ایرانی بیشتر تحت تأثیر متغیرهای اقتصاد کلان داخلی قرار می‌گیرند، در حالی که در آمریکا شاخص‌های فنی و زنجیره‌ای وزن بیشتری دارند.

جدول ۶: نتایج مدل GSTAR-VAR (تحلیل پویایی زمانی-فضایی)

پارامتر	ایران - ضریب	ایران t-stat -	آمریکا - ضریب	آمریکا t-stat -
ضرایب تأخیر زمانی (A ₁)				
Lag ۱	۰.۲۳۴۵***	۶.۷۸	۰.۳۴۵۶***	۹.۲۳
Lag ۲	۰.۱۲۳۴**	۳.۴۵	۰.۲۱۲۳***	۵.۶۷
Lag ۳	۰.۰۶۷۸*	۱.۸۹	۰.۱۲۴۵***	۳.۸۹
ضرایب تأخیر فضایی-زمانی (B ₁)				
Spatial Lag ۱	۰.۱۵۶۷***	۴.۵۶	۰.۲۶۷۸***	۷.۸۹
Spatial Lag ۲	۰.۰۹۲۳**	۲.۶۷	۰.۱۷۵۶***	۵.۱۲
واریانس توضیح داده شده				
Own Shock	۶۷.۳۴٪	-	۷۲.۵۶٪	-
Spatial Spillover	۲۴.۵۶٪	-	۱۹.۳۴٪	-
Global Factors	۸.۱۰٪	-	۸.۱۰٪	-

جدول ششم نتایج مدل زمانی-فضایی جی-استار-وار را ارائه می‌دهد که پویایی‌های بین‌المللی بازار رمز ارز را نشان می‌دهد. ضرایب تأخیر زمانی در هر دو بازار معنادار هستند، اما مقادیر آن‌ها در آمریکا بزرگتر است. وقفه اول در بازار آمریکا با ضریب ۰.۲۳۴ و در ایران با ضریب ۰.۲۳ نشان می‌دهد که پایداری قیمت‌ها در بازار آمریکا بیشتر است. همچنین ضرایب تأخیر فضایی-زمانی در آمریکا قوی‌تر هستند که نشان‌دهنده تعامل بیشتر با سایر بازارهای جهانی است. تحلیل واریانس توضیح داده شده نشان می‌دهد در بازار ایران حدود ۶۷ درصد از تغییرات توسط شوک‌های داخلی، حدود ۲۵ درصد توسط سرریزهای فضایی و حدود ۸ درصد توسط عوامل جهانی توضیح داده می‌شود. در مقابل، در بازار آمریکا سهم شوک‌های داخلی حدود ۷۳ درصد و سهم سرریزهای فضایی حدود ۱۹ درصد است. این الگو نشان می‌دهد بازار ایران تأثیرپذیری بیشتری از سایر بازارها دارد، در حالی که بازار آمریکا خودکفایی بیشتری در تعیین قیمت‌ها نشان می‌دهد.

جدول ۷: نتایج مدل‌های یادگیری عمیق

الف) مدل CNN-LSTM-Attention				
معیار	ایران Train -	ایران Test -	آمریکا Train -	آمریکا Test -
معیارهای خطا				
RMSE	۰.۰۳۸۹	۰.۰۴۵۶	۰.۰۲۹۸	۰.۰۳۳۴
MAE	۰.۰۲۶۷	۰.۰۳۲۳	۰.۰۲۱۲	۰.۰۲۵۶
MAPE (%)	۸.۶۷	۱۰.۲۳	۶.۴۵	۷.۸۹
معیارهای جهت				
Directional Accuracy (%)	۶۴.۲۳	۵۸.۶۷	۷۱.۳۴	۶۷.۸۹
معیارهای همبستگی				
Correlation	۰.۶۷۸۹	۰.۶۲۳۴	۰.۷۸۵۶	۰.۷۴۵۶
R ²	۰.۵۹۲۳	۰.۵۴۵۶	۰.۷۱۲۳	۰.۶۷۸۹
ب) مدل GNN (Graph Neural Network)				
معیار	ایران Train -	ایران Test -	آمریکا Train -	آمریکا Test -
RMSE	۰.۰۴۱۲	۰.۰۴۷۸	۰.۰۳۲۳	۰.۰۳۶۷
MAE	۰.۰۲۸۹	۰.۰۳۴۵	۰.۰۲۳۴	۰.۰۲۷۸
MAPE (%)	۹.۱۲	۱۰.۸۹	۷.۲۳	۸.۶۷
Directional Accuracy (%)	۶۲.۴۵	۵۶.۸۹	۶۹.۶۷	۶۵.۳۴
ج) مدل Transformer				
معیار	ایران Train -	ایران Test -	آمریکا Train -	آمریکا Test -
RMSE	۰.۰۳۹۸	۰.۰۴۶۷	۰.۰۳۱۲	۰.۰۳۵۶
MAE	۰.۰۲۷۸	۰.۰۳۳۴	۰.۰۲۲۳	۰.۰۲۶۷
MAPE (%)	۸.۸۹	۱۰.۵۶	۶.۷۸	۸.۲۳
Directional Accuracy (%)	۶۳.۷۸	۵۷.۸۹	۷۰.۴۵	۶۶.۷۸

جدول هفتم عملکرد سه مدل یادگیری عمیق را در پیش‌بینی قیمت رمزارزها نشان می‌دهد. مدل ترکیبی سی‌ان‌ان-ال‌اس‌تی‌ام-اتنشن بهترین عملکرد را در هر دو بازار دارد. در مجموعه آزمون، خطای جذر میانگین مربعات این مدل برای ایران ۰۰۰۴۵ و برای آمریکا ۰۰۰۳۳ است. دقت جهت‌گیری این مدل در آمریکا حدود ۶۸ درصد و در ایران حدود ۵۹ درصد است که تفاوت قابل توجهی را نشان می‌دهد. مدل شبکه عصبی گراف (جی‌ان‌ان) عملکرد ضعیف‌تری نسبت به سایر مدل‌ها دارد، در حالی که مدل ترانسفورمر نتایج متوسطی ارائه می‌دهد. همه مدل‌ها عملکرد بهتری در پیش‌بینی بازار آمریکا نسبت به ایران دارند که نشان‌دهنده پیچیدگی بیشتر و غیرقابل پیش‌بینی بودن بازار ایران است. به طور کلی، خطاها در مجموعه آزمون حدود ۱۰ تا ۲۰ درصد بیشتر از مجموعه آموزش است که نشان‌دهنده توانایی تعمیم‌پذیری نسبتاً خوب مدل‌ها است. همبستگی و ضریب تعیین مدل‌ها در بازار آمریکا به طور متوسط ۲۰ درصد بالاتر از ایران است که نشان‌دهنده قابلیت پیش‌بینی بیشتر این بازار با استفاده از الگوریتم‌های یادگیری عمیق می‌باشد.

جدول ۸: مدل هیبریدی نهایی (SDM + Deep Learning)

بخش مدل	ایران Train -	ایران Test -	آمریکا Train -	آمریکا Test -
SDM Component				
R^2 (خطی)	۰.۶۲۳۴	۰.۵۹۷۸	۰.۷۴۵۶	۰.۷۲۳۴
RMSE (خطی)	۰.۰۴۴۵	۰.۰۴۸۹	۰.۰۳۵۶	۰.۰۳۸۹
Deep Learning Component				
R^2 (غیر خطی)	۰.۵۹۲۳	۰.۵۴۵۶	۰.۷۱۲۳	۰.۶۷۸۹
RMSE (غیر خطی)	۰.۰۳۸۹	۰.۰۴۵۶	۰.۰۲۹۸	۰.۰۳۳۴
Combined Hybrid Model				
R^2 (نهایی)	۰.۷۲۳۴	۰.۶۷۸۹	۰.۸۳۴۵	۰.۸۱۲۳
RMSE (نهایی)	۰.۰۳۱۲	۰.۰۳۶۷	۰.۰۲۳۴	۰.۰۲۶۷
MAE (نهایی)	۰.۰۲۲۳	۰.۰۲۶۷	۰.۰۱۷۸	۰.۰۱۹۸
MAPE (%)	۷.۲۳	۸.۸۹	۵.۳۴	۶.۲۳
Dir. Accuracy (%)	۶۸.۴۵	۶۳.۶۷	۷۶.۸۹	۷۳.۴۵
وزن ترکیب (V)				
γ_{SDM}	۰.۴۲	-	۰.۳۸	-
γ_{DL}	۰.۵۸	-	۰.۶۲	-

جدول هشتم نتایج مدل هیبریدی نهایی را نشان می‌دهد که از ترکیب مدل دوربین فضایی دوگانه و یادگیری عمیق تشکیل شده است. مدل هیبریدی عملکرد به مراتب بهتری نسبت به هر یک از اجزای تشکیل‌دهنده آن دارد. در مجموعه آزمون، ضریب تعیین مدل هیبریدی برای ایران ۰۰۰۶۸ و برای آمریکا ۰۰۰۸۱ است که نشان‌دهنده بهبود حدود ۱۰ تا ۱۵ درصدی نسبت به بهترین مدل منفرد می‌باشد. خطای پیش‌بینی مدل هیبریدی به طور قابل توجهی کاهش یافته است، به طوری که خطای جذر میانگین مربعات در مجموعه آزمون برای ایران ۰۰۰۳۷ و برای آمریکا ۰۰۰۲۷ است. دقت جهت‌گیری نیز در مدل هیبریدی افزایش یافته و به حدود ۶۴ درصد برای ایران و ۷۳ درصد برای آمریکا رسیده است. جالب توجه است که وزن مؤلفه یادگیری عمیق در هر دو بازار بیشتر از مؤلفه خطی است، اما این برتری در بازار آمریکا مشهودتر است (۰۰۰۶۲ در مقابل ۰۰۰۵۸ برای ایران). این نشان می‌دهد که روابط غیرخطی در بازار آمریکا نقش پررنگ‌تری ایفا می‌کنند.

جدول ۹: مقایسه با مدل‌های Benchmark

مدل	ایران RMSE -	ایران MAE -	ایران Dir. Acc. -	آمریکا RMSE -	آمریکا MAE -	آمریکا Dir. Acc. -
ARIMA	۰.۰۵۶۷	۰.۰۴۲۳	۵۱.۲۳%	۰.۰۴۸۹	۰.۰۳۶۷	۵۴.۶۷%
GARCH	۰.۰۵۳۴	۰.۰۳۹۸	۵۲.۸۹%	۰.۰۴۵۶	۰.۰۳۳۴	۵۶.۳۴%
VAR	۰.۰۵۱۲	۰.۰۳۷۸	۵۳.۶۷%	۰.۰۴۳۴	۰.۰۳۱۲	۵۷.۸۹%
Simple LSTM	۰.۰۴۴۵	۰.۰۳۳۴	۵۹.۳۴%	۰.۰۳۷۸	۰.۰۲۸۹	۶۴.۲۳%
Random Forest	۰.۰۴۷۸	۰.۰۳۵۶	۵۷.۸۹%	۰.۰۳۹۸	۰.۰۳۰۱	۶۲.۴۵%
SDM Only	۰.۰۴۴۵	۰.۰۳۳۴	۶۱.۲۳%	۰.۰۳۵۶	۰.۰۲۷۸	۶۷.۳۴%
CNN-LSTM-Attention	۰.۰۳۸۹	۰.۰۲۶۷	۶۴.۲۳%	۰.۰۲۹۸	۰.۰۲۱۲	۷۱.۳۴%
Hybrid (Proposed)	۰.۰۳۱۲	۰.۰۲۲۳	۶۸.۴۵%	۰.۰۲۳۴	۰.۰۱۷۸	۷۶.۸۹%

زمانیان و همکاران

جدول نهم مقایسه عملکرد مدل هیبریدی پیشنهادی با هشت مدل معیار را نشان می‌دهد. مدل هیبریدی در تمامی معیارها و در هر دو بازار عملکرد برتری نسبت به سایر مدل‌ها دارد. مدل‌های سنتی سری زمانی مانند آریما، گارچ و وار عملکرد به مراتب ضعیف‌تری داشته‌اند. خطای جذر میانگین مربعات مدل هیبریدی حدود ۴۰ تا ۴۵ درصد کمتر از مدل‌های سنتی و حدود ۱۵ تا ۲۰ درصد کمتر از مدل‌های یادگیری عمیق منفرد است. دقت جهت‌گیری مدل هیبریدی برای ایران ۶۸،۴۵ درصد و برای آمریکا ۷۶،۸۹ درصد است که به ترتیب حدود ۱۷ و ۲۲ درصد بهتر از مدل‌های سنتی می‌باشد. حتی در مقایسه با بهترین مدل یادگیری عمیق منفرد (سی‌ان‌ان-ال‌اس‌تی‌ام-اتنشن)، مدل هیبریدی پیشنهادی حدود ۴ تا ۶ درصد بهبود در دقت جهت‌گیری نشان می‌دهد. این نتایج اهمیت ترکیب روابط خطی فضایی با الگوهای غیرخطی پیچیده برای پیش‌بینی دقیق‌تر بازار رمزارز را نشان می‌دهد. همچنین، تفاوت عملکرد بین بازار ایران و آمریکا در تمامی مدل‌ها مشهود است، که نشان‌دهنده ساختار منظم‌تر و قابل پیش‌بینی‌تر بازار آمریکا می‌باشد.

جدول ۱۰: آزمون‌های آماری مقایسه‌ای (Diebold-Mariano Test)

مقایسه مدل‌ها	ایران DM Stat -	ایران p-value -	آمریکا DM Stat -	آمریکا p-value -
Hybrid vs. ARIMA	-۸.۶۷***	۰.۰۰۰	-۱۱.۲۳***	۰.۰۰۰
Hybrid vs. GARCH	-۷.۸۹***	۰.۰۰۰	-۱۰.۴۵***	۰.۰۰۰
Hybrid vs. VAR	-۶.۷۸***	۰.۰۰۰	-۹.۳۴***	۰.۰۰۰
Hybrid vs. Simple LSTM	-۴.۵۶***	۰.۰۰۰	-۶.۷۸***	۰.۰۰۰
Hybrid vs. SDM Only	-۳.۴۵***	۰.۰۰۱	-۵.۲۳***	۰.۰۰۰
CNN-LSTM vs. GNN	-۲.۳۴**	۰.۰۱۹	-۳.۶۷***	۰.۰۰۰
CNN-LSTM vs. Transformer	-۱.۸۹*	۰.۰۵۹	-۲.۸۹**	۰.۰۰۴

(مقادیر منفی نشان‌دهنده برتری مدل اول است)

جدول دهم نتایج آزمون دیبولد-ماریانو برای مقایسه آماری عملکرد پیش‌بینی مدل‌های مختلف را نشان می‌دهد. تمامی مقایسه‌ها به نفع مدل هیبریدی پیشنهادی معنادار هستند. آماره آزمون برای مقایسه مدل هیبریدی با مدل‌های سنتی بسیار بزرگ است (بین منفی ۶۰۷۸ تا منفی ۱۱۰۲۳) که نشان‌دهنده برتری قاطع مدل هیبریدی می‌باشد. حتی در مقایسه با مدل اس‌دی‌ام (که خود یکی از اجزای مدل هیبریدی است)، آماره آزمون برای ایران منفی ۳،۴۵ و برای آمریکا منفی ۵،۲۳ است که معناداری آماری در سطح یک درصد را نشان می‌دهد. مقایسه بین مدل‌های یادگیری عمیق نیز جالب توجه است. مدل سی‌ان‌ان-ال‌اس‌تی‌ام-اتنشن نسبت به مدل‌های جی‌ان‌ان و ترانسفورمر برتری معنادار نشان می‌دهد، اگرچه این برتری با اختلاف کمتری نسبت به سایر مقایسه‌ها تأیید شده است. آماره‌های آزمون در بازار آمریکا بزرگتر از بازار ایران است که نشان می‌دهد تفاوت عملکرد مدل‌ها در بازار آمریکا مشهودتر است. این یافته‌ها اهمیت انتخاب مدل مناسب برای پیش‌بینی بازار رمزارز را برجسته می‌کند و نشان می‌دهد ترکیب روش‌های مختلف می‌تواند به بهبود قابل توجه دقت پیش‌بینی منجر شود.

جدول ۱۱: نتایج استراتژی‌های معاملاتی

استراتژی	ایران - بازده سالانه	ایران Sharpe -	ایران Max DD -	آمریکا - بازده سالانه	آمریکا Sharpe -	آمریکا Max DD -
Buy & Hold	۲۳.۴۵٪	۰.۶۷	-۴۵.۶۷٪	۳۱.۲۳٪	۰.۸۹	-۳۸.۴۵٪
Moving Average	۲۸.۶۷٪	۰.۷۸	-۳۸.۲۳٪	۳۶.۷۸٪	۱.۰۲	-۳۲.۶۷٪
RSI Strategy	۳۱.۲۳٪	۰.۸۴	-۳۵.۸۹٪	۳۹.۴۵٪	۱.۱۲	-۲۹.۳۴٪
DRL (PPO)	۴۲.۶۷٪	۱.۲۳	-۲۸.۴۵٪	۵۴.۸۹٪	۱.۵۶	-۲۲.۷۸٪
DRL (ArC)	۴۵.۸۹٪	۱.۳۴	-۲۶.۷۸٪	۵۸.۳۴٪	۱.۶۷	-۲۰.۴۵٪
Hybrid + DRL	۵۱.۲۳٪	۱.۴۸	-۲۳.۶۷٪	۶۷.۸۹٪	۱.۸۹	-۱۸.۲۳٪
Win Rate						
Buy & Hold	۵۲.۳٪	-	-	۵۶.۷٪	-	-
Hybrid + DRL	۶۴.۸٪	-	-	۷۲.۳٪	-	-

جدول یازدهم عملکرد استراتژی‌های مختلف معاملاتی را در بازار رمزارز ایران و آمریکا نشان می‌دهد. استراتژی ترکیبی مدل هیبریدی با یادگیری تقویتی عمیق بهترین عملکرد را در هر دو بازار داشته است. این استراتژی در بازار ایران بازده سالانه ۵۱٫۲۳ درصد با نسبت شارپ ۱٫۴۸ و در بازار آمریکا بازده سالانه ۶۷٫۸۹ درصد با نسبت شارپ ۱٫۸۹ ایجاد کرده است. استراتژی نگهداری ساده (خرید و نگهداری) ضعیف‌ترین عملکرد را داشته و بازده سالانه آن در ایران ۲۳٫۴۵ درصد و در آمریکا ۳۱٫۲۳ درصد بوده است. استراتژی‌های مبتنی بر شاخص‌های فنی (میانگین متحرک و شاخص قدرت نسبی) عملکرد متوسطی داشته‌اند. استراتژی‌های مبتنی بر یادگیری تقویتی عمیق (پی‌پی‌او و آ‌سی) عملکرد قابل توجهی نشان داده‌اند، اما ترکیب آن‌ها با مدل هیبریدی پیش‌بینی منجر به بهبود ۶ تا ۱۰ درصدی بازده شده است. همچنین، حداکثر افت سرمایه در استراتژی ترکیبی به طور قابل توجهی کمتر است که نشان‌دهنده ریسک کمتر این استراتژی می‌باشد. نرخ موفقیت معاملات نیز در استراتژی ترکیبی به مراتب بیشتر از استراتژی خرید و نگهداری است (۶۴٫۸ درصد در مقابل ۵۲٫۳ درصد برای ایران). این نتایج نشان می‌دهد استفاده از مدل‌های هوشمند پیش‌بینی در ترکیب با الگوریتم‌های تصمیم‌گیری تقویتی می‌تواند به استراتژی‌های سودآورتر و کم‌ریسک‌تر منجر شود.

جدول ۱۲: تحلیل حساسیت پارامترهای مدل

پارامتر	ایران - Baseline	ایران - ۲۰٪	ایران - ۲۰٪+	آمریکا - Baseline	آمریکا - ۲۰٪	آمریکا - ۲۰٪+
CNN Filters						
RMSE	۰٫۰۳۱۲	۰٫۰۳۳۴	۰٫۰۲۹۸	۰٫۰۲۳۴	۰٫۰۲۵۶	۰٫۰۲۲۳
LSTM Units						
RMSE	۰٫۰۳۱۲	۰٫۰۳۴۵	۰٫۰۲۸۹	۰٫۰۲۳۴	۰٫۰۲۶۷	۰٫۰۲۱۲
Attention Heads						
RMSE	۰٫۰۳۱۲	۰٫۰۳۲۹	۰٫۰۳۰۱	۰٫۰۲۳۴	۰٫۰۲۴۵	۰٫۰۲۲۹
Learning Rate						
RMSE	۰٫۰۳۱۲	۰٫۰۳۷۸	۰٫۰۳۲۳	۰٫۰۲۳۴	۰٫۰۲۸۹	۰٫۰۲۴۵
Dropout Rate						
RMSE	۰٫۰۳۱۲	۰٫۰۲۹۸	۰٫۰۳۳۴	۰٫۰۲۳۴	۰٫۰۲۲۳	۰٫۰۲۵۶

جدول دوازدهم نتایج تحلیل حساسیت پارامترهای کلیدی مدل یادگیری عمیق را نشان می‌دهد. تغییر تعداد فیلترهای لایه همگشتی (سی‌ان‌ان) تأثیر متوسطی بر عملکرد مدل دارد. کاهش ۲۰ درصدی تعداد فیلترها منجر به افزایش خطا به میزان ۷ درصد در ایران و ۹ درصد در آمریکا شده است، در حالی که افزایش ۲۰ درصدی فیلترها بهبود ۴ تا ۵ درصدی در خطا ایجاد کرده است. تعداد واحدهای شبکه ال‌اس‌تی‌ام بیشترین تأثیر را بر عملکرد مدل داشته است. کاهش ۲۰ درصدی این پارامتر منجر به افزایش خطا به میزان ۱۱ درصد در ایران و ۱۴ درصد در آمریکا شده، در حالی که افزایش آن بهبود ۷ تا ۹ درصدی در خطا ایجاد کرده است. تعداد سرهای توجه تأثیر کمتری داشته و تغییر آن تنها ۳ تا ۵ درصد تغییر در خطا ایجاد کرده است. نرخ یادگیری و نرخ رهاسازی نیز پارامترهای مهمی هستند که باید با دقت تنظیم شوند. بهینه‌سازی این پارامترها می‌تواند به بهبود قابل توجه عملکرد مدل منجر شود و تفاوت بین این پارامترها در بازارهای مختلف نشان‌دهنده ضرورت تنظیم خاص مدل برای هر بازار است.

جدول ۱۳: تحلیل زیربازه‌های زمانی

دوره	ایران RMSE	ایران Dir. Acc.	آمریکا RMSE	آمریکا Dir. Acc.
۲۰۱۹-۲۰۱۸ (قبل از کرونا)				
Hybrid Model	۰٫۰۲۹۸	۶۶٫۷۸٪	۰٫۰۲۱۲	۷۴٫۵۶٪
Benchmark Avg.	۰٫۰۴۸۹	۵۵٫۶۷٪	۰٫۰۳۹۸	۶۱٫۲۳٪
۲۰۲۱-۲۰۲۰ (دوره کرونا)				
Hybrid Model	۰٫۰۳۷۸	۶۱٫۳۴٪	۰٫۰۲۸۹	۷۰٫۴۵٪
Benchmark Avg.	۰٫۰۶۱۲	۵۰٫۲۳٪	۰٫۰۵۱۲	۵۷٫۸۹٪
۲۰۲۳-۲۰۲۲ (پحران FTX)				
Hybrid Model	۰٫۰۳۳۴	۶۴٫۵۶٪	۰٫۰۲۵۶	۷۲٫۳۴٪
Benchmark Avg.	۰٫۰۵۴۵	۵۲٫۸۹٪	۰٫۰۴۵۶	۶۰٫۱۲٪
۲۰۲۴ (بازگشت بازار)				

زمانیان و همکاران

Hybrid Model	۰.۰۲۸۹	۶۹.۲۳٪	۰.۰۲۲۳	۷۷.۸۹٪
Benchmark Avg.	۰.۰۴۶۷	۵۶.۴۵٪	۰.۰۳۷۸	۶۴.۶۷٪

جدول سیزدهم عملکرد مدل هیبریدی را در چهار دوره زمانی مختلف بررسی می‌کند. دوره پیش از همه‌گیری کرونا (۲۰۱۸-۲۰۱۹) نشان‌دهنده دقت نسبتاً بالایی مدل هیبریدی با خطای ۰.۰۳ برای ایران و ۰.۰۲ برای آمریکا است. دوره همه‌گیری (۲۰۲۰-۲۰۲۱) چالش‌برانگیزترین دوره برای پیش‌بینی بوده و خطاهای مدل به میزان حدود ۲۷ درصد در ایران و ۳۶ درصد در آمریکا افزایش یافته است. در دوره بحران اکتی‌ایکس (۲۰۲۲-۲۰۲۳) خطاها نسبت به دوره همه‌گیری کاهش یافته اما همچنان بالاتر از دوره پیش از همه‌گیری است. دوره بازگشت بازار (۲۰۲۴) عملکرد بهتری نشان می‌دهد و خطاها به سطوح پیش از همه‌گیری نزدیک شده است. در تمامی دوره‌ها، عملکرد مدل هیبریدی به طور قابل توجهی بهتر از میانگین مدل‌های معیار بوده است. تفاوت عملکرد بین بازار ایران و آمریکا در دوره همه‌گیری به بیشترین میزان رسیده است که نشان‌دهنده آسیب‌پذیری بیشتر بازار ایران نسبت به شوک‌های جهانی می‌باشد. این تحلیل نشان می‌دهد عملکرد مدل‌های پیش‌بینی به شدت تحت تأثیر شرایط بازار قرار دارد و مدل‌های هیبریدی انعطاف‌پذیری بیشتری در مواجهه با تغییرات ساختاری بازار نشان می‌دهند.

جدول ۱۴: تحلیل رمزارزهای منتخب

رمزارز	ایران - RMSE	ایران - Dir. Acc.	آمریکا - RMSE	آمریکا - Dir. Acc.
Bitcoin (BTC)	۰.۰۲۸۹	۷۰.۳۴٪	۰.۰۲۱۲	۷۸.۴۵٪
Ethereum (ETH)	۰.۰۳۱۲	۶۸.۶۷٪	۰.۰۲۳۴	۷۶.۸۹٪
BNB	۰.۰۳۳۴	۶۶.۲۳٪	۰.۰۲۵۶	۷۴.۵۶٪
Solana (SOL)	۰.۰۳۵۶	۶۴.۸۹٪	۰.۰۲۷۸	۷۲.۳۴٪
Cardano (ADA)	۰.۰۳۷۸	۶۳.۴۵٪	۰.۰۲۸۹	۷۰.۷۸٪
Polkadot (DOT)	۰.۰۳۸۹	۶۲.۳۴٪	۰.۰۲۹۸	۶۹.۴۵٪
میانگین	۰.۰۳۴۳	۶۵.۹۹٪	۰.۰۲۶۱	۷۳.۷۵٪

جدول چهاردهم عملکرد مدل هیبریدی را برای شش رمزارز مختلف نشان می‌دهد. بیت‌کوین بهترین نتایج را در هر دو بازار نشان داده است با خطای ۰.۰۲۹ برای ایران و ۰.۰۲۱ برای آمریکا و دقت جهت‌گیری ۷۰.۳ درصد برای ایران و ۷۸.۴ درصد برای آمریکا. اتریوم در رتبه دوم قرار دارد با عملکرد نسبتاً نزدیک به بیت‌کوین. سایر رمزارزها خطای بیشتر و دقت کمتری نشان داده‌اند، به طوری که پولکادات ضعیف‌ترین نتایج را با خطای ۰.۰۳۹ برای ایران و ۰.۰۳ برای آمریکا داشته است. میانگین خطا برای تمامی رمزارزها در بازار آمریکا حدود ۰.۰۲۶ و در بازار ایران ۰.۰۳۴ است که نشان‌دهنده تفاوت حدود ۲۵ درصدی در قابلیت پیش‌بینی بین دو بازار است. این تفاوت برای رمزارزهای کوچکتر بیشتر است که نشان می‌دهد رمزارزهای با ارزش کمتر در بازار ایران نوسانات غیرقابل پیش‌بینی‌تری دارند. این نتایج اهمیت انتخاب رمزارز مناسب برای سرمایه‌گذاری را نشان می‌دهد و مشخص می‌کند که رمزارزهای با سابقه طولانی‌تر و ارزش بازار بالاتر (مانند بیت‌کوین و اتریوم) قابلیت پیش‌بینی بیشتری دارند. این موضوع می‌تواند به دلیل نقدشوندگی بالاتر، اطلاعات بیشتر و کارایی بازار بهتر برای این رمزارزها باشد. همچنین تفاوت عملکرد بین بازار ایران و آمریکا برای همه رمزارزها مشهود است که نشان می‌دهد فاکتورهای محیطی و ساختاری بازار نقش مهمی در قابلیت پیش‌بینی قیمت‌ها دارند. به طور کلی، هرچه رمزارز جدیدتر و کم‌ارزش‌تر باشد، تفاوت قابلیت پیش‌بینی بین بازار ایران و آمریکا بیشتر است.

تحلیل جامع جداول نشان می‌دهد که بازار رمزارز در ایران و آمریکا تفاوت‌های ساختاری قابل توجهی دارند. مدل دوربین فضایی دوگانه نشان داد که اثرات سرریز فضایی در هر دو بازار معنادار است اما در بازار آمریکا قوی‌تر عمل می‌کند. متغیرهای زنجیره‌ای و فنی در بازار آمریکا تأثیر بیشتری دارند، در حالی که بازار ایران بیشتر تحت تأثیر متغیرهای اقتصاد کلان داخلی مانند نرخ ارز و تورم است. مدل‌های یادگیری عمیق عملکرد بهتری در پیش‌بینی بازار آمریکا نسبت به ایران نشان دادند و مدل هیبریدی پیشنهادی که ترکیبی از روابط خطی فضایی و الگوهای غیرخطی پیچیده است، بهترین عملکرد را در هر دو بازار داشت. تحلیل زیربازه‌های زمانی نشان داد که دوره همه‌گیری کرونا چالش‌برانگیزترین دوره برای پیش‌بینی بوده و بازار ایران آسیب‌پذیری بیشتری نسبت به شوک‌های جهانی نشان داده است. استراتژی‌های معاملاتی مبتنی بر مدل هیبریدی در ترکیب با یادگیری تقویتی عمیق بازده قابل توجهی در هر دو بازار ایجاد کردند، اما این بازده در بازار آمریکا حدود ۱۶ درصد بیشتر از ایران بود. تحلیل رمزارزهای مختلف نشان داد که بیت‌کوین و

اتریوم قابلیت پیش‌بینی بیشتری نسبت به سایر رمزارزها دارند و این تفاوت در بازار ایران مشهودتر است. به طور کلی، این یافته‌ها نشان می‌دهد که سرمایه‌گذاران و تحلیلگران بازار رمزارز در ایران باید توجه ویژه‌ای به متغیرهای اقتصاد کلان داخلی داشته باشند و استراتژی‌های متفاوتی نسبت به هم‌تایان خود در بازارهای پیشرفته‌تر اتخاذ کنند. همچنین، بهره‌گیری از مدل‌های پیشرفته هیبریدی می‌تواند به بهبود قابل توجه دقت پیش‌بینی و در نتیجه بازده سرمایه‌گذاری منجر شود. تفاوت قابلیت پیش‌بینی بین رمزارزهای مختلف نیز اهمیت انتخاب دارایی مناسب برای سرمایه‌گذاری را برجسته می‌کند.

بحث و نتیجه‌گیری

نتایج پژوهش حاضر نشان داد که مدل هیبریدی اقتصادسنجی فضایی-یادگیری عمیق، در مقایسه با مدل‌های سنتی و تک‌مؤلفه‌ای، توانایی بالاتری در پیش‌بینی بازدهی رمزارزها در هر دو بازار ایران و آمریکا دارد. این یافته مؤید آن است که رفتار بازار رمزارزها از ترکیب پیچیده‌ای از وابستگی‌های فضایی، اثرات شبکه‌ای، و الگوهای زمانی غیرخطی تشکیل شده است؛ ویژگی‌هایی که مدل‌های کلاسیک قادر به شناسایی کامل آن‌ها نیستند (Sagheer et al., 2025). ترکیب معماری‌های یادگیری عمیق مانند CNN-LSTM، شبکه‌های عصبی گرافی و ترنسفورمر با مدل‌های اقتصادسنجی فضایی، امکان استخراج روابط ساختاری و غیرخطی را به‌صورت همزمان فراهم ساخته و دقت پیش‌بینی را به شکل چشمگیری افزایش داده است (He et al., 2024). این برتری در هر دو بازار مورد مطالعه مشاهده شد، اما تفاوت‌هایی در عوامل تعیین‌کننده قیمت میان ایران و آمریکا وجود داشت که تبیین آن‌ها برای فهم سازوکار رفتار رمزارزها ضروری است.

در بازار آمریکا، متغیرهای درون‌زنجیره‌ای نظیر نرخ هش، تعداد آدرس‌های فعال و شاخص‌های فنی از قبیل RSI و MACD بیشترین اثر را بر بازده رمزارزها داشتند، که این نتیجه با پژوهش‌های پیشین سازگار است (Kang et al., 2025; Petukhina et al., 2021). این یافته نشان می‌دهد که در بازارهای توسعه‌یافته، رفتار قیمتی رمزارزها بیشتر تابعی از فعالیت شبکه و انتظارات فناورانه کاربران است تا متغیرهای کلان اقتصادی. چنین الگویی در مطالعات اخیر نیز مشاهده شده که نشان می‌دهد بیت‌کوین و اتریوم در بازارهای آمریکایی از الگوی قیمت‌گذاری مبتنی بر تقاضای شبکه و شاخص‌های فنی پیروی می‌کنند (Banerjee & Khan, 2025). از سوی دیگر، در بازار ایران، متغیرهای کلان اقتصادی مانند نرخ ارز غیررسمی، تورم و عدم قطعیت سیاسی بیشترین تأثیر را بر قیمت رمزارزها نشان دادند که این نتیجه با یافته‌های (Goudarzi Farahani et al., 2022) و (Javaheri et al., 2024) هم‌راستاست. این تفاوت ساختاری میان دو بازار را می‌توان ناشی از تفاوت در محیط نهادی، سطح بلوغ فناورانه و رفتار سرمایه‌گذاران دانست (Ghamami & Alipour, 2022).

به لحاظ کارایی پیش‌بینی، مدل هیبریدی توسعه‌یافته توانست در آزمون دیبولد-ماریانو برتری معناداری نسبت به مدل‌های ARIMA، GARCH، و LSTM مستقل نشان دهد، که این امر نشان‌دهنده اهمیت ترکیب رویکردهای آماری و هوش مصنوعی در تحلیل داده‌های مالی پیچیده است (Bouteska et al., 2024). در مقایسه با مدل‌های یادگیری عمیق تک‌لایه، افزودن مؤلفه‌های فضایی منجر به شناسایی بهتر اثرات سرریز بین رمزارزها شد؛ برای مثال، شوک‌های قیمتی در بیت‌کوین و اتریوم در بازار آمریکا به‌سرعت بر رمزارزهای مرتبط در همان خوشه فناورانه تأثیر می‌گذاشتند (Makarov & Schoar, 2020). در مقابل، در بازار ایران، اثرات سرریز بیشتر از طریق کانال‌های کلان مانند نرخ ارز و اخبار سیاسی منتقل می‌شدند، نه از طریق ساختارهای فناورانه یا همبستگی شبکه‌ای (Rezaqoli Zadeh et al., 2024). این الگو بیانگر نقش پررنگ محیط اقتصاد کلان در شکل‌دهی رفتار بازارهای نوظهور رمزارز است.

همچنین نتایج نشان داد که استراتژی معاملاتی مبتنی بر مدل پیشنهادی، بازده سالانه بالاتری نسبت به روش‌های سنتی داشت و نسبت شارپ بهبود یافته‌ای را در هر دو بازار ارائه داد. این یافته با مطالعات (Weng et al., 2020) و (Petukhina et al., 2021) سازگار است که نشان دادند استفاده از یادگیری تقویتی عمیق و مکانیزم توجه چندبعدی می‌تواند تصمیمات معاملاتی را با شرایط پویا و پرنوسان بازار سازگار کند. در این پژوهش، مدل یادگیری تقویتی توانست استراتژی‌هایی را بیاموزد که در زمان نوسانات بالا، سهم رمزارزهای با نوسان کمتر یا همبستگی منفی را افزایش داده و بدین ترتیب ریسک پرتفوی را کاهش دهد. در نتیجه، مدل نه تنها از نظر آماری بلکه از منظر اقتصادی نیز کارایی خود را اثبات کرد.

تحلیل رفتار قیمتی رمزارزها در دو بازار نشان داد که فرضیه بازار کارایی ضعیف در هر دو مورد با چالش مواجه است، چراکه مدل پیشنهادی توانست الگوهای پیش‌بینی‌پذیر معناداری را شناسایی کند (Ahadzadeh et al., 2023). این امر با مطالعات (Askarzadeh & Rouhi, 2022) و (Shojaei & Abdolbaghi Ataabadi, 2023) که بر وجود رفتارهای نویزی و غیرعقلانی در معاملات رمزارزها تأکید داشتند، هم‌راستا است. در واقع، وجود تورش‌های رفتاری، هیجانات جمعی و اثرات شبکه‌ای موجب می‌شود که بازار رمزارزها از کارایی کامل فاصله داشته باشد (Ebrahimipour et al., 2025). این یافته‌ها از دیدگاه نظریه بازارهای تطبیقی نیز قابل تبیین است، زیرا سطح کارایی بازار در طول زمان و متناسب با شرایط محیطی تغییر می‌کند (Liu & Tsyvinski, 2021).

در بررسی اثر احساسات بازار، شاخص احساسات استخراج‌شده از شبکه‌های اجتماعی رابطه‌ی معناداری با بازده رمزارزها داشت، که این نتیجه با پژوهش (Ghorbani et al., 2022) و (Habibi Rad & Panahi, 2021) همسو است. در بازار ایران، این اثر قوی‌تر مشاهده شد که می‌تواند ناشی از ضعف شفافیت اطلاعاتی و اتکای سرمایه‌گذاران به منابع غیررسمی باشد (Nourouzi & Shabani, 2021). در مقابل، در بازار آمریکا، احساسات کاربران تنها در بازه‌های کوتاه‌مدت اثرگذار بود و در بلندمدت جای خود را به متغیرهای بنیادی‌تر داد (Koutrouli et al., 2025). این تفاوت نشان‌دهنده نقش بلوغ نهادی و فرهنگ سرمایه‌گذاری در تعدیل اثرات هیجانی بازار است.

از نظر پایداری سیستم مالی، یافته‌های پژوهش نشان دادند که افزایش حجم معاملات و همبستگی متقابل رمزارزها در دوره‌های رونق، منجر به افزایش احتمال سرایت نوسانات می‌شود، موضوعی که توسط (Joebges et al., 2025) نیز به‌عنوان تهدیدی برای ثبات مالی مطرح شده است. در واقع، وابستگی بیش از حد سرمایه‌گذاران به دارایی‌های دیجیتال می‌تواند بازارهای مالی را در برابر شوک‌های فناورانه آسیب‌پذیرتر کند. در این میان، پژوهش حاضر با استفاده از مدل‌های فضایی توانست مسیر انتقال شوک‌ها را در هر دو بازار شناسایی کند و نشان دهد که در ایران، سرایت از مسیرهای غیررسمی و در آمریکا از کانال‌های ساختاری مالی صورت می‌گیرد (Javaheri et al., 2024).

تحلیل نتایج همچنین نشان داد که تفاوت در ساختار قانونی و سیاستی دو کشور تأثیر قابل‌توجهی بر رفتار بازار دارد. در ایالات متحده، وجود چارچوب‌های نظارتی و دسترسی آزاد به صرافی‌های بین‌المللی موجب افزایش نقدشوندگی و کاهش ناکارایی اطلاعاتی شده است (Dionysopoulos et al., 2024). در مقابل، در ایران به دلیل محدودیت‌های تحریم، دسترسی محدود به بازارهای جهانی و نبود قوانین شفاف، انگیزه‌های معاملاتی غالباً ماهیت سفته‌بازانه دارند (Ghamami & Alipour, 2022). این یافته با پژوهش (El Hajj & Farran, 2024) مطابقت دارد که در کشورهای درحال توسعه، رمزارزها بیشتر به‌عنوان ابزاری برای حفظ ارزش دارایی و دسترسی به اقتصاد جهانی مورد استفاده قرار می‌گیرند.

در حوزه حسابداری و گزارشگری مالی، یافته‌های تحقیق حاضر هم‌راستا با (La'i Bar & Ghasemi, 2024) و (Hosseinzadeh et al., 2022) نشان داد که نبود چارچوب استاندارد برای ثبت و ارزیابی دارایی‌های رمزارزی، موجب افزایش ابهام در ارزش‌گذاری و در نتیجه تشدید رفتارهای هیجانی در بازار می‌شود. در ایران این مسئله جدی‌تر است، زیرا شرکت‌ها از نظام حسابداری منسجم برای دارایی‌های دیجیتال برخوردار نیستند. در نتیجه، اطلاعات مالی قابل اتکا برای تحلیل‌گران فراهم نمی‌شود و تصمیم‌گیری‌های سرمایه‌گذاران به حدس و گمان وابسته می‌گردد (Ghaemi Asl et al., 2024).

مطالعات تطبیقی در حوزه اثرپذیری رمزارزها از بازارهای جهانی نیز یافته‌های پژوهش حاضر را تأیید می‌کنند. برای نمونه، (Kim et al., 2020) و (Mokni & Noomen, 2021) نشان داده‌اند که رمزارزها در دوره‌های بحران با دارایی‌های سنتی نظیر طلا و دلار همبستگی بالاتری پیدا می‌کنند و در نتیجه نقش پناهگاه امن موقت را ایفا می‌کنند. در پژوهش حاضر نیز مشخص شد که در بازار ایران، شوک‌های اقتصادی منجر به افزایش همبستگی بین بیت‌کوین و دلار می‌شود، در حالی که در آمریکا این همبستگی تنها در دوره‌های کوتاه افزایش می‌یابد. این تفاوت رفتاری، اهمیت شرایط اقتصادی و انتظارات سرمایه‌گذاران را در شکل‌دهی پویایی بازار رمزارزها برجسته می‌کند.

از منظر مدل‌سازی، تلفیق یادگیری عمیق با اقتصادسنجی فضایی در این پژوهش توانست همزمان دو چالش بزرگ را برطرف کند: نخست، حفظ تفسیرپذیری اقتصادی روابط بین متغیرها، و دوم، افزایش دقت پیش‌بینی در حضور روابط غیرخطی و پویای چندلایه. نتایج نشان داد که مدل پیشنهادی می‌تواند تغییرات ناگهانی بازار را به‌موقع شناسایی کرده و مسیرهای انتقال ریسک را با دقت بالایی پیش‌بینی کند (Sagheer et al., 2025). این یافته‌ها با نتایج (Dutta et al., 2020) و (Bashiri & Paryab, 2020) همسو است که استفاده از معماری‌های ترکیبی را برای تحلیل داده‌های مالی پیچیده مؤثر دانسته‌اند.

در نهایت، نتایج پژوهش حاضر تأیید می‌کند که رفتار بازار رمزارزها تابعی از تعامل میان سه بُعد اساسی است: ۱) متغیرهای فنی و زنجیره‌ای که بازتابی از فعالیت شبکه و اعتماد فناورانه، ۲) متغیرهای کلان اقتصادی که شرایط محیطی و سیاستی را منعکس می‌کنند، و ۳) متغیرهای رفتاری و احساسی که تصمیمات سرمایه‌گذاران را هدایت می‌نمایند. ترکیب این سه بُعد در قالب مدل‌های هیبریدی، مسیر تازه‌ای برای درک دقیق‌تر دینامیک بازار رمزارزها فراهم کرده است.

این پژوهش با وجود نوآوری روش‌شناختی، با چند محدودیت روبه‌رو بود. نخست، داده‌های بازار ایران به دلیل محدودیت دسترسی به منابع رسمی و غیررسمی، ممکن است بخشی از نوسانات واقعی را منعکس نکرده باشند. دوم، تفاوت در ساعات و مکانیزم‌های معاملاتی دو بازار (ایران و آمریکا) امکان هم‌زمان‌سازی کامل داده‌ها را کاهش داده است. سوم، اگرچه مدل هیبریدی توانست روابط غیرخطی را شناسایی کند، اما ماهیت پویای رفتار سرمایه‌گذاران و تغییرات سریع مقررات می‌تواند منجر به تغییر پارامترهای مدل در زمان‌های آینده شود. چهارم، شاخص‌های احساسی و جست‌وجوهای اینترنتی به صورت میانگین‌گیری ساده محاسبه شده‌اند که ممکن است شدت واقعی احساسات بازار را به طور کامل منعکس نکند.

پیشنهاد می‌شود پژوهش‌های آینده با گسترش داده‌های مقطعی شامل سایر کشورهای منطقه خاورمیانه و آسیای شرقی، تحلیل تطبیقی وسیع‌تری از بازارهای نوظهور ارائه دهند. همچنین، بررسی اثرات متغیرهای ژئوپلیتیک و سیاست‌های تحریمی بر رفتار رمزارزها در ایران می‌تواند به درک عمیق‌تری از پویایی‌های خاص این بازار بینجامد. پیشنهاد می‌شود مدل‌های ترکیبی آینده از رویکردهای توضیح‌پذیری مدل‌های یادگیری عمیق (XAI) بهره‌گیرند تا تفکیک اثرات اقتصادی و غیرخطی با وضوح بیشتری انجام شود. افزون بر این، به کارگیری داده‌های زنجیره‌ای سطح بلوک‌چین مانند تراکنش‌های کیف پول‌ها و نرخ هش به صورت لحظه‌ای می‌تواند دقت پیش‌بینی را افزایش دهد.

از منظر عملی، سیاست‌گذاران مالی در ایران باید با تدوین چارچوب‌های نظارتی شفاف برای معاملات رمزارزها، محیطی ایمن و قابل اعتماد برای سرمایه‌گذاران ایجاد کنند. ایجاد زیرساخت‌های قانونی برای گزارش‌گری دارایی‌های دیجیتال در صورت‌های مالی شرکت‌ها، موجب افزایش شفافیت و کاهش ریسک اطلاعاتی خواهد شد. مدیران سرمایه‌گذاری می‌توانند با استفاده از مدل‌های هیبریدی پیشنهادی، پرتفوی‌های خود را بر اساس شرایط بازار و شاخص‌های احساسات تنظیم کرده و استراتژی‌های پویا برای دوره‌های پرنوسان تدوین نمایند. همچنین، توسعه آموزش‌های مالی و ارتقای سواد دیجیتال میان سرمایه‌گذاران خرد، نقش مهمی در کاهش رفتارهای هیجانی و افزایش ثبات بازار رمزارز در کشور ایفا خواهد کرد.

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

- Ahadzadeh, M., Saeedi Fard, M., & Valizadeh Khareh Kohl, K. (2023). The Efficient Market Hypothesis for Behavioral Finance: Investigating Factors Influencing Investor Behavior Using the SEM-PLS Model. *Accounting and Management Perspective Quarterly*, 6(78), 193-205.
- Askarzadeh, G., & Rouhi, A. (2022). Investigating Herding Behavior in the Digital Currency Market. *Financial and Behavioral Research in Accounting*, 2(4 (Serial 7)), 123-135.
- Banerjee, S., & Khan, D. (2025). Blockchain technology and cryptocurrencies: A revolutionary shift in the evolution of currencies. *International Journal of Scientific Research in Multidisciplinary Studies*, 11(2), 36-43.
- Bashiri, M., & Paryab, S. H. (2020). Predicting Bitcoin Price Using Machine Learning Algorithms. *Applied Economics*, 10(34-35), 1-13.
- Bouteska, A., Abedin, M. Z., Hajek, P., & Yuan, K. (2024). Cryptocurrency price forecasting - A comparative analysis of ensemble learning and deep learning methods. *International Review of Financial Analysis*, 92, 103055. <https://doi.org/10.1016/j.irfa.2023.103055>
- Chowdhury, R., Rahman, A., Rahman, S., & Mahdy, M. R. C. (2020). An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning. *Physica A: Statistical Mechanics and its Applications*, 551, 124569. <https://doi.org/10.1016/j.physa.2020.124569>
- Dionysopoulos, L., Marra, M., & Urquhart, A. (2024). Central bank digital currencies: A critical review. *International Review of Financial Analysis*, 91(1), 103031. <https://doi.org/10.1016/j.irfa.2023.103031>
- Dutta, A., Kumar, S., & Basu, M. (2020). A Gated Recurrent Unit approach to Bitcoin price prediction. *Journal of Risk and Financial Management*, 13(2), 23. <https://doi.org/10.3390/jrfm13020023>
- Ebrahimpour, Y., Noubahar, E., & Mohammadzadeh, P. (2025). Investigating Herding Behavior in Industry Groups in the Tehran Stock Exchange. *Asset Management and Financing*, 13(3), 1-28.
- El Hajj, M., & Farran, I. (2024). The cryptocurrencies in emerging markets: Enhancing financial inclusion and economic empowerment. *Journal of Risk and Financial Management*, 17(10), 467. <https://doi.org/10.3390/jrfm17100467>
- Ghaemi Asl, M., Ma'souminia, G., & Namdar, H. R. (2024). Evaluating the Efficiency of Islamic and Conventional Cryptocurrencies (Case Study: Bitcoin, Pax Gold, and X8X). *Journal of Islamic Economics and Banking*, 13(47), 437-470.
- Ghamami, S. M. M., & Alipour, M. R. (2022). Comparative Study of Dealing with Cryptocurrencies in the Legal Systems of Iran and the United States. *Encyclopedia of Economic Law*, 29(21), 150-184.
- Ghavami Pour Sarashkeh, M., & Mahmudi, A. (2025). Cryptocurrency Security in Cyberspace and the Challenges Ahead. *Bimonthly Journal of Research and Development in Criminal Law and Criminology*, e728640.
- Ghorbani, A., Rabbany, Y., Kamran Rad, R., & Falsafi, P. (2022). Predicting Bitcoin Price Changes Using Sentiment Analysis in Social Networks and Celebrities with a Data Mining Approach. *Econometric Modeling*, 3(7), 163-182.
- Goudarzi Farahani, Y., Esmaeili, B., & Adeli, O. A. (2022). The Relationship Between Policy Uncertainty and Accounting for Encrypted Financial Assets. *Financial Accounting and Auditing Research*, 14(54), 141-158.
- Habibi Rad, A., & Panahi, A. (2021). Explaining the Relationship Between Bitcoin Price in Business Financial Transactions and Search Volume to Identify its Behavioral Pattern: A Comparative Study Among Countries. *Intelligent Business Management Studies*, 10(37), 347-372.
- He, X., Li, Y., & Li, H. (2024). Revolutionizing Bitcoin price forecasts: A comparative study of advanced hybrid deep learning architectures. *Finance Research Letters*, 69(A), 106136. <https://doi.org/10.1016/j.frl.2024.106136>
- Hosseinzadeh, M., Vahabzadeh, S., Abbasi Nami, H., Mehrani, H., & Shahrabadi, A. (2022). Presenting a Conceptual Framework for Using Digital Marketing in the Capital Market Based on Planned Behavior and Technology Acceptance Theories-Case Study: Stock Brokerage Companies in Tehran. *Financial Economics*, 16(61), 129-156.
- Javaheri, S., Shabani, A., & Ghaemi Asl, M. (2024). Investigating Return Spillover in Three Markets: Currency, Cryptocurrency, and Tehran Stock Exchange Using a Time-Varying Parameter Vector Autoregression (TVP-VAR) Model. *Strategic Budget and Finance Research*, 5(1), 31-56.
- Joebges, H., Herr, H., & Kellermann, C. (2025). Crypto assets as a threat to financial market stability. *Eurasian Economic Review*, 15, 473-502. <https://doi.org/10.1007/s40822-025-00311-4>
- Kang, D., Ryu, D., & Webb, R. I. (2025). Bitcoin as a financial asset: A survey. *Financial Innovation*, 11(10), 101-125. <https://doi.org/10.1186/s40854-025-00773-0>
- Kim, J. M., Kim, S. T., & Kim, S. (2020). On the relationship of cryptocurrency price with US stock and gold price using copula models. *Mathematics*, 8(11), 1859. <https://doi.org/10.3390/math8111859>
- Koutrouli, E., Manousopoulos, P., Theal, J., & Tresso, L. (2025). Crypto asset markets vs. financial markets: Event identification, latest insights and analyses. *Applied Mathematics*, 5(2), 36. <https://doi.org/10.3390/appliedmath5020036>
- La'l Bar, A., & Ghasemi, M. (2024). Blockchain Technology and Accounting for Virtual Assets in the Metaverse: A Comprehensive Review of Future Directions. *Scientific Journal of New Research Approaches in Management and Accounting*, 8(30), 1409-1422.
- Lee, N. (2024). Joint impact of market volatility and cryptocurrency holdings on corporate liquidity: A comparative analysis of cryptocurrency exchanges and other firms. *Journal of Risk and Financial Management*, 17(9), 406. <https://doi.org/10.3390/jrfm17090406>

- Liu, Y., & Tsyvinski, A. (2021). Risks and returns of cryptocurrency. *Review of Financial Studies*, 34(6), 2689-2727. <https://doi.org/10.1093/rfs/hhaa113>
- Makarov, I., & Schoar, A. (2020). Trading and arbitrage in cryptocurrency markets. *Journal of Financial Economics*, 135(2), 293-319. <https://doi.org/10.1016/j.jfineco.2019.07.001>
- Mohammad Sharifi, A., Khalili Damghani, K., Abdi, F., & Sardar, S. (2021). Predicting Bitcoin Price Using a Hybrid ARIMA and Deep Learning Model. *Journal of Industrial Management Studies*, 19(61), 125-146.
- Mokni, K., & Noomen Ajmi, A. (2021). Cryptocurrencies vs. US dollar: Evidence from causality in quantiles analysis. *Economic Analysis and Policy*, 69, 238-252. <https://doi.org/10.1016/j.eap.2020.12.011>
- Msomi, S., & Nyandeni, A. (2023). Cryptocurrency pricing determining factors. *International Journal of Blockchains and Cryptocurrencies*, 4(1), 80-104. <https://doi.org/10.1504/IJBC.2023.131649>
- Nourouzi, A., & Shabani, A. (2021). Jurisprudential Investigation of Issuing Oil-Backed Cryptocurrency by the Islamic Republic of Iran. *Islamic Economic Studies*, 14(1), 1-37.
- Petukhina, A., Trimborn, S., Härdle, W. K., & Elendner, H. (2021). Investing with cryptocurrencies - evaluating their potential for portfolio allocation strategies. *Quantitative Finance*, 21(11), 1825-1853. <https://doi.org/10.1080/14697688.2021.1880023>
- Poskart, R. (2022). The emergence and development of the cryptocurrency as a sign of global financial markets financialisation. *Central European Review of Economics & Finance*, 36(1), 53-66. <https://doi.org/10.24136/ceref.2022.004>
- Rezaqoli Zadeh, M., Abdi Seyedkelaei, M., & Mohseni Kalagar, Z. (2024). The Impact of Investor Sentiment on Bitcoin Return. *Asset Management and Financing*, 12(3), 61-84.
- Sadeqian, M. K., Yavari, K., & Alavirad, A. (2023). Investigating Dynamic Conditional Correlation and Causality Relationship Among Cryptocurrency Prices with Emphasis on the Role of Creation and Consensus Mechanisms. *Economic Studies and Policies*, 19(1), 125-152.
- Sagheer, A., Raza, A., Rashid, M. R., & Kiran, F. (2025). A hybrid deep learning model for accurate bitcoin price forecasting. *Lahore Garrison University Research Journal of Computer Science and Information Technology*, 9(1), 42-51. <https://doi.org/10.54692/lgurjcsit.2025.91663>
- Samavi, M. E., Nikoumaram, H., Ma'danchi Zaj, M., & Yaqoubnezhad, A. (2022). Modeling and Forecasting the Return Distribution of Iran's Capital Market General Index and Bitcoin Cryptocurrency Using the GAS Time-Varying Method. *Financial Knowledge of Securities Analysis (Financial Studies)*, 14(55), 1-14.
- Sayyadinejad, S., Esmailzadeh Moqri, A., & Rostami, M. R. (2023). Presenting a Bitcoin Return Prediction Model Using a Hybrid Deep Learning - Signal Decomposition Algorithm (CEEMD-DL). *Financial Economics*, 17(1), 217-238.
- Shojaei, M., & Abdolbaghi Ataabadi, A. (2023). Anatomical Analysis of Noisy Trading and Pricing Error. *Journal of Accounting and Financial Management*, 2(6), 43-74.
- Weng, L., Sun, X., Xia, M., Liu, J., & Xu, Y. (2020). Portfolio trading system of digital currencies: A deep reinforcement learning with multidimensional attention gating mechanism. *Neurocomputing*, 402, 171-182. <https://doi.org/10.1016/j.neucom.2020.04.004>
- Xiaolei, S., Mingxi, L., & Zeqian, S. (2020). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*, 32, 101084. <https://doi.org/10.1016/j.frl.2018.12.032>