



Securities & Exchange Organization, Research, Development & Islamic Studies (RDIS)
Quarterly Journal of Securities Exchange, Fall 2026, V. 19, No.75, pp. 135-170

Forecasting Tehran Stock Market Return Using Quantum Artificial Intelligence Algorithms¹

Reza Maaboudi², Younes Nademi³, Soheila Aghaei⁴

Received: 16 October 2025 Revised: 11 May 2026

Accepted: 13 July 2026 Published Online: 18 August 2026

Research Paper

Highlights

- Utilizing a hybrid framework of deep learning and quantum computing to forecast stock market returns.
- Comprehensive comparison of QDL performance with GRU, LSTM, SVR, RF and ARIM models.
- QDL outperforms other models based on Mean Squared Error, Root Mean Squared Error, and Theil's index.
- Confirmation of the statistically significant superiority of the QDL model over the examined models, based on Diebold–Mariano and Wilcoxon tests.
- Ability of QDL to detect hidden and nonlinear patterns in the stock market, enabled by quantum computing features such as superposition and entanglement.

Abstract

This study aims to forecast the returns of the Tehran Stock Market by employing the novel Quantum Deep Learning (QDL) approach. To this end, daily data of the Tehran Stock Exchange Value-Weighted Index over the period from February 1, 2016 to October 6, 2025 are used to compute stock market returns. Subsequently, stock market returns are modeled and predicted using a Quantum Deep Learning framework, which integrates the capabilities of deep learning and quantum computing. The predictive performance of the proposed model is benchmarked against six competing models, including the ARIMA model, machine learning algorithms such as Random Forest and Support Vector Regression, as well as deep learning models including LSTM, GRU, and MLP. The results based on Mean Squared Error, Root Mean Squared Error, and Theil's index indicate that the QDL model outperforms all competing models in forecasting stock market returns. Moreover, the Diebold–Mariano and Wilcoxon tests confirm the statistical significance of the superior predictive accuracy of the proposed model, thereby reinforcing the robustness of the error-based evaluation results. The distinctive characteristics of quantum computing, such as superposition and entanglement, enable the Quantum Deep Learning model to more effectively capture hidden and nonlinear patterns in stock market dynamics, leading to improved performance under conditions of heightened volatility and unpredictable market behavior. Based on the empirical findings, it is recommended that the Securities and Exchange Organization facilitate the development and adoption of advanced technologies such as quantum computing by establishing the necessary infrastructure, thereby enabling smarter market surveillance and the early detection of potential bubbles and systemic risks.

Keywords: Stock Return Forecasting, Tehran Stock Market, Quantum Deep Learning.


JEL Classification: D53, E44, G17.

1. doi: [10.22034/jse.2026.12631.2400](https://doi.org/10.22034/jse.2026.12631.2400)

2. Associate Professor, Department of Economics, Faculty of Humanities, Ayatollah Boroujerdi University, Boroujerd, Iran, (Corresponding Author). (maaboudi@abru.ac.ir).

3. Associate Professor, Department of Economics, Faculty of Humanities, Ayatollah Boroujerdi University, Boroujerd, Iran, (Younesnademi@abru.ac.ir).

4. M.A. Student in Economics, Department of Economics, Faculty of Humanities, Ayatollah Boroujerdi University, Boroujerd, Iran. (stusheilaaghaee@abru.ac.ir).



Copyright © 2026 The Authors. Published by Securities and Exchange Organization.

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0

International license (<https://creativecommons.org/licenses/by-nc/4.0/>). Non-commercial uses of the work are permitted, provided the original work is properly cited.

Cite This Article: Maaboudi, Reza; Nademi, Younes; Aghaei, Soheila; (2026). Forecasting Tehran Stock Market Return Using Quantum Artificial Intelligence Algorithms. *Quarterly Journal of Securities Exchange*, 19 (75), 135-170.

<https://doi.org/10.22034/jse.2026.12631.2400>. Homepage: <https://journal.seo.ir>

Introduction

The stock market plays a crucial role in modern economies by connecting investors and savers, collecting scattered capital, and channeling it toward profitable investments. Its attractiveness encourages capital accumulation in productive sectors and enables it to play a potentially significant role in national development. Furthermore, the stock market contributes to economic efficiency by reallocating financial resources among firms and economic sectors, facilitating domestic liquidity growth and credit expansion. Accordingly, forecasting stock market returns and analyzing their impacts on investment decisions and economic assessments have always been key concerns for investors and financial analysts. However, the stock market is characterized by volatility and exposure to multiple risks; therefore, employing suitable models for predicting its returns remains an important and challenging issue in financial research. In practice, this complexity has encouraged researchers to experiment with various modeling approaches for predicting stock market returns. In recent years, the presence of nonlinear behavior and the complex structure of stock market indices and variables have reduced the appeal of conventional econometric techniques for return forecasting. Conversely, rapid advancements in artificial intelligence (AI) and machine learning (ML) have opened new avenues for financial prediction. Among these developments, their capacity to process vast volumes of data simultaneously, extract more intricate patterns, and improve predictive accuracy and efficiency. These unique features have made QDL algorithms increasingly attractive to both financial analysts and policymakers. In light of these developments, the present study seeks to examine the feasibility and performance of QDL algorithms in forecasting the Tehran Stock Market returns and to compare their accuracy and efficiency with those of competing models.

Methodology

In this study, daily data from the Tehran Stock Exchange's market-value-weighted price index are used to calculate stock market returns over the period February 1, 2016, to October 7, 2025. For modeling and forecasting purposes, 80 percent of the dataset is allocated to model training and the remaining 20 percent to model testing. The Quantum Deep Learning (QDL) model, which combines the capabilities of deep learning with the computational power of quantum mechanics, is compared with six alternative models: the classical ARIMA time series model, Random Forest (RF), Support Vector Regression (SVR), and deep learning models including Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and Multilayer Perceptron (MLP). Since stock market return prediction involves high-frequency trading data with time-series characteristics, a Quantum Long Short-Term Memory (QLSTM) network is employed to capture temporal dependencies and dynamic relationships

within the data. The models' forecasting performance is evaluated using three standard error metrics: Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Theil's U statistic. The model yielding the lowest errors across these measures is considered the most efficient. To ensure robustness of the results, the Diebold–Mariano (DM) test is applied to assess the statistical significance of the differences between forecast errors produced by the QDL model and those generated by the competing models.

Findings and Discussion

The forecasting error indicators reveal show that the classical ARIMA model performs relatively poorly, highlighting its limited ability to capture the nonlinear and volatile dynamics of stock returns. Machine learning and deep learning models perform better, reflecting their capacity to detect hidden dependencies and nonlinear patterns. Among these, the Quantum Deep Learning (QDL) model achieves the lowest forecasting errors, while MLP, RF, LSTM, GRU, and SVR also outperform ARIMA. Comparison of error metrics and Theil's U statistics indicates that deep and quantum-based models provide higher predictive accuracy than traditional econometric approaches. Consistent with these findings, descriptive statistics of the actual and predicted returns show close alignment, demonstrating the model's ability to reproduce the underlying dynamics of real market data. To validate the statistical significance of this advantage, the Diebold–Mariano and Wilcoxon signed-rank tests are applied. Results from both tests confirm that the QDL model's forecasts are significantly more accurate than those of competing models, reinforcing the robustness of its predictive superiority.

Graphical and numerical comparisons further illustrate strong agreement between QDL predictions and observed returns, indicating that the model effectively captures market behavior even under high volatility. The QDL model maintains stable performance across normal and turbulent market periods, underscoring its reliability and robustness for stock return forecasting. These results highlight the value of combining deep learning with quantum-inspired mechanisms, enabling the model to identify complex temporal dependencies and nonlinear structures that traditional or classical machine learning models may miss. Overall, the QDL model demonstrates a significant advantage in forecasting accuracy and robustness, supporting its application for more informed investment decisions and market monitoring.

Conclusion

The study's findings confirm that the Quantum Deep Learning model outperforms all competing models in terms of efficiency and accuracy in predicting stock returns. The QDL approach, by incorporating quantum entanglement, enables the retention of complex time-series patterns and

nonlinear dependencies that traditional models cannot capture. The distinctive properties of quantum computation, superposition and entanglement, empower QDL to identify hidden structures in stock market data and to maintain superior performance under volatile and unpredictable market environments. Overall, employing the QDL model can serve as an effective tool for reducing uncertainty and minimizing forecasting errors in investment decision-making. Consequently, it provides an efficient mechanism for improving investment strategies, mitigating decision-making risks, and enhancing the analytical precision of financial models. For retail investors, QDL helps reduce the risk of losses resulting from emotional

reactions or incomplete information. For institutional investors and portfolio managers, it offers a data-driven method to anticipate market trends, optimize asset allocation, manage systematic risks, and improve portfolio performance. At the macroeconomic level, the use of advanced predictive tools such as QDL can enhance market transparency and public trust, both of which are vital for the expansion of financial markets and the attraction of domestic and foreign investments. Therefore, based on the study's findings, it is recommended that the Tehran Stock Exchange and the Securities and Exchange Organization establish the necessary infrastructure for the adoption and implementation of advanced technologies such as quantum computing. Such advancements can be utilized to enable smarter market monitoring, early detection of speculative bubbles, and identification of potential financial crises, thereby supporting a more stable and efficient capital market environment.

Authors' Contributions

All authors contributed equally to the design, execution, and writing of all parts of this research.

Funding

There is no funding support.

Conflict of Interest

The authors declare no conflicts of interest relevant to the content of this article.

Acknowledgments

We thank the anonymous reviewers for their useful comments, which greatly contributed to improving our work



سازمان بورس و اوراق بهادار، مدیریت پژوهش، توسعه و مطالعات اسلامی

فصلنامه بورس اوراق بهادار، سال نوزدهم، شماره ۷۵، پاییز ۱۴۰۵، صص ۱۷۰-۱۳۵

پیش‌بینی بازدهی بازار سهام تهران با استفاده از الگوریتم‌های

هوش مصنوعی کوانتومی^۱

رضا معبودی^۲، یونس نادمی^۳، سهیلا آقایی^۴

تاریخ دریافت: ۱۴۰۴/۰۷/۲۴ تاریخ بازنگری: ۱۴۰۵/۰۲/۲۱

تاریخ پذیرش: ۱۴۰۵/۰۴/۲۲ تاریخ انتشار: ۱۴۰۵/۰۵/۲۷

مقاله پژوهشی

نکات برجسته

- استفاده از چارچوب ترکیبی یادگیری عمیق و محاسبات کوانتومی برای پیش‌بینی بازدهی بازار سهام.
- مقایسه جامع عملکرد QDL با مدل‌های GRU، LSTM، SVR، RF و ARIMA.
- کاهش خطاهای پیش‌بینی الگوی QDL نسبت به الگوهای مورد بررسی براساس معیارهای خطا میانگین مربعات خطا، ریشه میانگین مربعات خطا و شاخص تایل.
- تأیید برتری معنادار آماری الگوی QDL نسبت به الگوهای مورد بررسی برپایه آزمون‌های دایبولد-ماریانو و ویلکاکسون.
- توانایی الگوی QDL در شناسایی الگوهای پنهان و غیرخطی بازار سهام به‌واسطه ویژگی‌های برهم‌نهی و درهم‌تنیدگی محاسبات کوانتومی.

چکیده

هدف پژوهش حاضر پیش‌بینی بازدهی بازار سهام تهران با استفاده از رویکرد نوین یادگیری عمیق کوانتومی (QDL) است. به‌همین منظور، نخست با استفاده از داده‌های روزانه شاخص قیمت وزنی - ارزش بازار سهام تهران در بازه زمانی دوازدهم بهمن سال ۱۳۹۴ تا پانزدهم مهرماه سال ۱۴۰۴ بازده بازار سهام محاسبه شد؛ سپس بازدهی بازار سهام با بکارگیری مدل یادگیری عمیق کوانتومی که ترکیبی از قابلیت‌های یادگیری عمیق و محاسبات کوانتومی است، همراه با شش مدل رقیب شامل مدل‌های ARIMA، الگوریتم‌های یادگیری ماشین RF، SVR و مدل‌های یادگیری عمیق LSTM، GRU و MLP مدل‌سازی و پیش‌بینی شد. نتایج مقایسه معیارهای میانگین مربعات خطا، ریشه میانگین مربعات خطا و شاخص تایل نشان داد، در پیش‌بینی بازدهی بازار سهام مدل QDL نسبت به سایر مدل‌های مورد بررسی عملکرد بهتری دارد. یافته‌های آزمون‌های دایبولد-ماریانو و ویلکاکسون نیز برتری معنادار آماری مدل پیشنهادی را نسبت به مدل‌های رقیب تأیید کردند که اعتبار یافته‌های حاصل از معیارهای خطا را تقویت می‌کند. ویژگی‌های منحصر به فرد محاسبات کوانتومی نظیر برهم‌نهی و درهم‌تنیدگی موجب می‌شود، مدل یادگیری عمیق کوانتومی توانایی بالاتری در شناسایی الگوهای پنهان و غیرخطی بازار سهام داشته باشد و در مواجهه با نوسانات شدید و رفتارهای غیرقابل پیش‌بینی بازار عملکرد بهتری از خود نشان دهد. براساس یافته‌های پژوهش، به سازمان بورس و اوراق بهادار پیشنهاد می‌شود با ایجاد زیرساخت‌های لازم برای توسعه و به کارگیری فناوری‌های پیشرفته‌ای مانند محاسبات کوانتومی، زمینه استفاده گسترده‌تر از این مدل‌ها را فراهم آورده و از آن‌ها در جهت نظارت هوشمندتر بر بازار و شناسایی زود هنگام حباب‌ها و بحران‌های بالقوه بهره‌برداری نماید.

واژه‌های کلیدی: پیش‌بینی بازدهی سهام، بازار سهام تهران، یادگیری عمیق کوانتومی.

طبقه‌بندی موضوعی: D53، E44، G17.

doi: 10.22034/jse.2026.12631.2400

۲. دانشیار، گروه اقتصاد، دانشکده علوم انسانی، دانشگاه آیت الله بروجردی (ره)، بروجرد، ایران، (نویسنده مسئول). (maaboudi@abru.ac.ir).

۳. دانشیار، گروه اقتصاد، دانشکده علوم انسانی، دانشگاه آیت الله بروجردی (ره)، بروجرد، ایران. (Younesnademi@abru.ac.ir).

۴. دانشجوی کارشناسی ارشد، گروه اقتصاد، دانشکده علوم انسانی، دانشگاه آیت الله العظمی بروجردی، بروجرد، ایران. (stusheilaaghaee@abru.ac.ir).

حق انتشار این مستند، متعلق به نویسندگان آن است. © ۱۴۰۵. ناشر این مقاله، سازمان بورس و اوراق بهادار است. این مقاله تحت گواهی زیر منتشر شده و هر نوع استفاده غیرتجاری از آن مشروط بر استناد صحیح به مقاله و با رعایت شرایط مندرج در آدرس زیر مجاز است.



Creative Commons Attribution-NonCommercial 4.0 International license

(https://creativecommons.org/licenses/by-nc/4.0/)

استناد: معبودی، رضا؛ نادمی، یونس؛ آقایی، سهیلا. (۱۴۰۵). پیش‌بینی بازدهی بازار سهام تهران با استفاده از الگوریتم‌های

هوش مصنوعی کوانتومی. *فصلنامه بورس اوراق بهادار*، ۱۹ (۷۵)، ۱۳۵-۱۷۰.

Homepage: <https://journal.seo.ir> Homepage: <https://doi.org/10.22034/jse.2026.12631.2400>

مقدمه

بازار سهام با برقراری ارتباط بین سرمایه‌گذاران و پس‌اندازکنندگان، سرمایه‌های خرد را جمع‌آوری و به‌سمت سرمایه‌گذاری سودآور سوق می‌دهد (ابراهیم و موسی^۱، ۲۰۱۴). وجود جذابیت‌های موجود در بازار سهام باعث می‌شود این بازار با تجهیز سرمایه‌گذاری در بخش‌های مولد اقتصاد، به صورت بالقوه نقش مهمی در توسعه کشورها ایفا کند (نمکی و کاظمی باویل، ۱۴۰۴). علاوه بر این، بازار سهام با تخصیص مجدد منابع مالی بین شرکت‌ها و بخش‌های مختلف اقتصادی، رشد نقدینگی داخلی و توسعه اعتباری را تسهیل می‌کند (ایساکو، اوستارزو دومانبان^۲، ۲۰۱۳). بازار سهام یک سیستم مالی است که با مدیریت صحیح و کارآمد می‌تواند در مقایسه با عایدی سایر بازارهای مالی، مانند سود سپرده بانکی و سود اوراق قرضه، بازدهی بالاتری را دارا باشد (محمد، احمد، نوید و بنده چاچه^۳، ۲۰۲۴). ویژگی‌هایی چون حجم بالای معاملات و سودآوری در بازار سهام، معامله‌گران و سرمایه‌گذاران را متقاعد می‌کند تا از طریق سرمایه‌گذاری در این محیط بتوانند بازدهی سرمایه خود را حداکثر کنند (مهرکیان و داوری اردکانی، ۲۰۲۵؛ رضایی، عبدالطیف و عامر^۴، ۲۰۲۵).

تغییرات بازدهی بازار سهام که ناشی از تغییرات شاخص کل قیمت سهام است، انتظارات افراد و فعالان بازار سرمایه، روند کلی ورود و خروج سرمایه، و در نهایت تحرکات بازار سرمایه را منعکس می‌کند (فطرس و معبودی، ۲۰۲۱). لذا پیش‌بینی بازدهی بازار سهام و تحلیل آثار آن بر تصمیمات سرمایه‌گذاری و تحلیل‌های اقتصادی، همواره مورد توجه سرمایه‌گذاران و تحلیل‌گران حوزه مالی قرار دارد (گوپتا، ناچاپا و پاراماند^۵، ۲۰۲۵).

اما بازار سهام رفتاری پرنوسان دارد و ریسک‌های متعددی را شامل می‌شود؛ به همین علت، استفاده از الگوهای مناسب برای پیش‌بینی بازدهی بازار سهام چالشی مهم و قابل توجه در حوزه بازارهای مالی است. به‌طوری که در عمل باعث شده پژوهشگران در زمینه پیش‌بینی بازدهی بازار سهام از مدل‌های مختلفی استفاده کنند. به دلیل وجود رفتارهای غیرخطی و ماهیت پیچیده شاخص‌ها و متغیرهای بازار سهام، بهره‌گیری از اقتصادسنجی مرسوم در پیش‌بینی بازدهی بازار

1. Ibrahim & Musah
2. Isshaku, Ustarz & Domanban
3. Muhammad, Naveed & Bendeache
4. Rezaei, Abdellatif & Umar
5. Gupta, Nachappa & Parahnandan

سهام می‌تواند با خطا همراه شود (گوپتا و همکاران، ۲۰۲۵). محدودیت دیگر در استفاده از الگوهای مرسوم این است که در پیش‌بینی تنها تعداد اندک و محدودی از عوامل تاثیرگذار بر بازار سهام را در نظر می‌گیرند. به همین دلیل اغلب الگوهای مرسوم در پیش‌بینی بازار سهام از دقت کافی و لازم برخوردار نیستند (وو، وانگ و دنگ^۱، ۲۰۲۵).

در سال‌های اخیر، پیشرفت‌های چشمگیر در حوزه هوش مصنوعی و الگوریتم‌های یادگیری ماشین^۲، افق‌های تازه‌ای برای پیش‌بینی بازارهای مالی گشوده است. بررسی این الگوها نشان می‌دهد ارتباط بین الگوریتم‌های هوش مصنوعی و بازارهای مالی نه تنها بهبود تدریجی نسبت به روش‌های کلاسیک و مرسوم نیست، بلکه به عنوان یک تغییر پارادایم در پیش‌بینی بازارهای مالی نیز محسوب می‌شود. این تغییر پارادایم از سه تحول کلیدی ناشی می‌شود. نخست، الگوریتم‌های هوش مصنوعی برخلاف الگوهای اقتصادسنجی مرسوم قادرند الگوهای پیچیده و غیرخطی داده‌های مالی با ابعاد بالا را شناسایی کنند؛ دوم، با ادغام داده‌های متنوع از جمله رفتار قیمتی، تحلیل احساسات و صورت‌های مالی، دیدی چند بعدی ایجاد می‌کنند. سوم، تطبیق‌پذیری الگوریتم‌های هوش مصنوعی سبب می‌شود به صورت همزمان با تغییرات بازار سهام هماهنگ شوند و قدرت پیش‌بینی خود را حفظ کنند (پاگلیارو^۳، ۲۰۲۵). این ویژگی‌ها باعث شده‌اند تا در سال‌های اخیر بکارگیری الگوریتم‌های هوش مصنوعی در پیش‌بینی شاخص‌های بازار سهام از استقبال فراوانی برخوردار شوند. در بین این الگوریتم‌ها، الگوریتم‌های یادگیری عمیق کوانتومی^۴ به دلیل توانایی در پردازش همزمان حجم عظیمی از داده‌ها، استخراج الگوهای پیچیده‌تر و ارتقای کارایی و دقت پیش‌بینی، به عنوان یکی از رویکردهای نوظهور و متمایز شناخته می‌شوند؛ رویکردی که می‌تواند نسبت به دیگر مدل‌های هوش مصنوعی برتری قابل توجهی در تحلیل و پیش‌بینی بازارهای مالی ایجاد کند.

با وجود پیشرفت‌های گسترده در حوزه مدل‌سازی مالی، بررسی ادبیات موضوع نشان می‌دهد که تاکنون هیچ مطالعه‌ای در بازار سرمایه ایران الگوریتم یادگیری عمیق کوانتومی را برای پیش‌بینی رفتار بازار سهام مورد آزمون قرار نداده است. این خلأ پژوهشی در حالی وجود دارد که ماهیت پرنوسان، غیرخطی و چندبعدی بازار سهام ایران نیازمند رویکردهایی است که

-
1. Wu, Wang & Deng
 2. machine learning
 3. Pagliaro
 4. Quantum Deep Learning

قدرت استخراج الگوهای پیچیده و پنهان را داشته باشند. با توجه به توضیحات فوق، پرسش اصلی پژوهش این است که آیا مدل یادگیری عمیق کوانتومی می‌تواند دقت و کارایی پیش‌بینی بازدهی بازار سهام ایران را نسبت به مدل‌های کلاسیک سری‌های زمانی، الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق کلاسیک بهبود دهد؟ در این راستا، پژوهش حاضر با بهره‌گیری از داده‌های سری زمانی روزانه در بازه دوازدهم بهمن‌ماه ۱۳۹۴ تا پانزدهم مهرماه ۱۴۰۴ و به‌کارگیری الگوریتم یادگیری عمیق کوانتومی، به مدل‌سازی و پیش‌بینی بازدهی بازار سهام ایران می‌پردازد. نتایج پژوهش می‌تواند برای سرمایه‌گذاران، تحلیل‌گران مالی و سیاست‌گذاران بازار سرمایه کاربرد مستقیم داشته باشد؛ زیرا پیش‌بینی دقیق‌تر بازدهی، زمینه‌ساز تصمیم‌گیری آگاهانه‌تر در خصوص زمان ورود و خروج از بازار، مدیریت ریسک و بهینه‌سازی پرتفوی خواهد بود. از این‌رو، نتایج پژوهش نه تنها از نظر علمی نوآورانه است، بلکه از منظر کاربردی نیز برای بازار سرمایه ایران قابل توجه است.

مبانی نظری و توسعه فرضیه‌ها

الگوهای کلاسیک از رویکردهای رایج در پیش‌بینی قیمت سهام به‌شمار می‌روند. این الگوها با تکیه بر مفروضات خطی، ایستا و نرمال بودن داده‌ها، تفسیری پایه و نظری از رفتار متغیرها ارائه می‌کنند و عمدتاً برای پیش‌بینی روندهای سری زمانی و تحلیل نوسانات استفاده می‌شوند. هرچند این مدل‌ها به دلیل ساختار ساده خود کاربرد گسترده‌ای دارند، اما در مواجهه با داده‌های پیچیده و غیرخطی بازارهای مالی با محدودیت‌های قابل توجهی روبه‌رو هستند (رن و لی، ۲۰۲۵). از این‌رو، در سال‌های اخیر الگوریتم‌های یادگیری ماشین به‌عنوان رویکردی کارآمدتر برای پیش‌بینی بازار سهام مورد توجه گسترده پژوهشگران و تحلیل‌گران مالی قرار گرفته‌اند.

مدل‌های یادگیری ماشین در حوزه مالی، به‌ویژه پیش‌بینی بازار سهام کاربرد گسترده‌ای دارند؛ زیرا برخلاف روش‌های سنتی نیازی به تعریف و تصریح مدل‌های نظری یا فروض خطی بودن داده‌ها ندارند. الگوریتم‌های یادگیری ماشین قادرند روابط غیرخطی، همبستگی‌های پیچیده و وابستگی‌های پویا را در داده‌های مالی شناسایی کنند و از این طریق دقت پیش‌بینی بازار سهام را به‌طور چشمگیری بهبود بخشند (جاوید^۲، ۲۰۲۴). همچنین، این الگوها امکان

1. Ren & Li

2. Javaid

پردازش داده‌های حجیم و بدون ساختار مانند اخبار، شبکه‌های اجتماعی و نظرات سرمایه‌گذاران را فراهم می‌کند. به همین دلیل، یادگیری ماشین به ابزاری قدرتمند برای پیش‌بینی بازدهی بازار سهام و تحلیل ریسک‌های مالی تبدیل شده است (پاگلیارو، ۲۰۲۵).

با این حال، پیش‌بینی بازار سهام با استفاده از الگوریتم‌های یادگیری ماشین با چالش‌هایی نیز همراه است. یکی از مهم‌ترین این چالش‌ها بیش‌برازش^۱ است؛ وضعیتی که در آن مدل‌ها اگرچه در داده‌های آموزشی عملکرد قابل قبولی دارند، اما به دلیل ماهیت پیچیده و غیرایستای بازارهای مالی، توان تعمیم آن‌ها به داده‌های جدید کاهش می‌یابد. علاوه بر این، نوسانات شدید و غیرقابل پیش‌بینی بازار سهام می‌تواند اثربخشی مدل‌های آموزش‌دیده را تحت تأثیر قرار دهد (سریواستاوا و همکاران^۲، ۲۰۲۳). کیفیت و دسترسی پذیری مجموعه داده‌ها نیز عاملی تعیین‌کننده است؛ چراکه داده‌های مالی اغلب دارای نویز، مقادیر گم‌شده و سوگیری‌های مختلف هستند و این موارد می‌تواند عملکرد مدل‌ها را تضعیف کند (محمد و همکاران، ۲۰۲۴).

با توجه به محدودیت‌های مدل‌های کلاسیک و الگوریتم‌های یادگیری ماشین از جمله ضعف در تعمیم‌پذیری، حساسیت به نوسانات شدید بازار و دشواری در شناسایی وابستگی‌های پیچیده و چندبعدی ضرورت بهره‌گیری از رویکردهای نوین بیش از پیش احساس می‌شود. در این راستا، مدل‌های یادگیری عمیق کوانتومی به عنوان رویکرد جدیدی مطرح شده‌اند که اصول محاسبات کوانتومی را با روش‌های یادگیری عمیق ترکیب می‌کند (ژای، ژانگ، لیانگ و لیو^۳، ۲۰۲۵). بهره‌گیری از ویژگی‌های بنیادی مکانیک کوانتومی از جمله برهم‌نهی کوانتومی^۴ و درهم‌تنیدگی^۵ امکان پردازش دقیق‌تر داده‌های پیچیده و با تواتر بالا را فراهم می‌سازد. برهم‌نهی به سیستم‌های کوانتومی اجازه می‌دهد مسیرهای محاسباتی متعدد را به طور هم‌زمان بررسی کنند و بدین ترتیب توانایی آن‌ها در شناسایی وابستگی‌های پیچیده در داده‌های مالی افزایش می‌یابد. درهم‌تنیدگی نیز همبستگی‌های قوی‌تری میان متغیرها ایجاد کرده و به نمایش غنی‌تر ویژگی‌ها و بهبود فرآیند شناسایی الگوها منجر می‌شود؛ موضوعی که مدل‌های کلاسیک در دستیابی به آن با دشواری مواجه‌اند (چودری، اینان، شفیق و سینگ^۶، ۲۰۲۵). این قابلیت‌ها موجب می‌شود

1. Overfitting
2. Srivastava et al.
3. Zhai, Zhang, Liang & Liu
4. Quantum Superposition
5. Quantum Entanglement
6. Choudhary, Innan, Shafique & Singh

پیش‌بینی‌های مبتنی بر مدل‌های یادگیری عمیق کوانتومی دقیق‌تر، پایدارتر و مقاوم‌تر در برابر نویز و نوسانات بازار باشد و در نهایت، ابزار قدرتمندی برای سرمایه‌گذاران و تحلیل‌گران در اتخاذ تصمیمات مالی فراهم آورد (چهیمی، چن، سعد و یو^۱، ۲۰۲۴).

توسعه فرضیه

با توجه به محدودیت‌ها و ضعف‌های مدل‌های کلاسیک سری‌های زمانی مانند ARIMA در مواجهه با داده‌های پرنویز، غیرخطی و دارای ساختار پیچیده، و همچنین محدودیت الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق سنتی در استخراج وابستگی و الگوهای پیچیده در داده‌های مالی، این پژوهش بر این فرض استوار است که مدل یادگیری عمیق کوانتومی با بهره‌گیری از ویژگی‌های مکانیک کوانتومی مانند برهم‌نهی، درهم‌تنیدگی و قدرت نمایش‌دهندگی بالاتر در فضای ویژگی‌ها، قادر است الگوهای پیچیده‌تر و غیرخطی بازار سهام ایران را به‌طور مؤثرتری شناسایی کند. از این رو، انتظار می‌رود QDL در مقایسه با مدل‌های کلاسیک سری‌های زمانی، الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق سنتی، دقت و کارایی بالاتری در پیش‌بینی بازدهی بازار سهام ارائه دهد.

فرضیه پژوهش

مدل یادگیری عمیق کوانتومی (QDL) در پیش‌بینی بازدهی بازار سهام، عملکرد بهتری نسبت به مدل‌های کلاسیک سری‌های زمانی، الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق سنتی دارد.

در ادامه تعدادی از مطالعات پیشین انجام شده در زمینه بازدهی بازار سهام با استفاده از مدل‌های مختلف آورده شده است.

پاکت و سلیمانی^۲ (۲۰۲۲) یک سیستم جهش کوانتومی^۳ برای پیش‌بینی بازارهای مالی طراحی و معرفی کردند. این سیستم شامل یک کد گذرا است که سری زمانی مالی تقسیم شده را به دنباله‌ای از ماتریس‌های چگالی تبدیل می‌کند؛ همچنین، یک شبکه کوانتومی عمیق که

1. Chehimi, Chen, Saad & Yoo

2. Paquet & Soleymani

3. Quantum Leap

ماتریس چگالی را در زمان‌های بعدی پیش‌بینی می‌کند و یک شبکه کلاسی^۱ که از ماتریس چگالی خروجی، بیشترین قیمت رسیده به یک دارایی را در زمان بعدی اندازه‌گیری می‌کند. نتایج مربوط به ۲۴ دارایی نشان می‌دهد دقت و کارایی سیستم جهش کوانتومی در دو حالت برآورد آینده و رگرسیون تایید شده است. کیا و همکاران^۲ (۲۰۲۴) با بهره‌گیری از رویکرد ترکیبی کوانتومی - کلاسی پیش‌بینی قیمت سهام را بررسی کردند. در این پژوهش، مدل حافظه بلند مدت کوتاه مدت کلاسیکی را با محاسبات کوانتومی ترکیب کرده و یک مدل جدید حافظه بلند مدت کوتاه مدت کوانتومی ارائه داده‌اند. نتایج نشان می‌دهند ریشه میانگین مربعات خطا در مدل کلاسیکی ۰/۰۶۹۳ و دقت پیش‌بینی آن ۰/۸۸۱۵ برآورد شده است. در حالی که مدل حافظه بلند مدت کوتاه مدت کوانتومی در هر دو مورد عملکرد بهتری نسبت به مدل کلاسیکی داشت و به ترتیب ریشه میانگین مربعات خطا ۰/۰۶۲۰ و دقت ۰/۹۷۶۳ داشته است. محمود و همکاران^۳ (۲۰۲۴) با استفاده از مدل‌های حافظه بلند مدت کوانتومی و حافظه بلند مدت کوتاه مدت، ۱۰۰ شاخص بورس کراچی را طی دوره زمانی ۲۰۰۴-۲۰۲۰ بررسی کردند. نتایج حاکی است مدل حافظه بلند مدت کوتاه مدت کوانتومی یک تکنیک بالقوه و قدرتمند برای پیش‌بینی روندهای بازار سهام است. ژو و همکاران^۴ (۲۰۲۴) یک میدان زاویه‌ای گرمیان کوانتومی^۵ طراحی کردند که ترکیبی از محاسبات کوانتومی و یادگیری عمیق برای پیش‌بینی تحلیل سری‌های زمانی است. نتایج حاکی است میدان زاویه‌ای گرمیان کوانتومی در مقایسه با روش سنتی (میدان زاویه‌ای گرمیان) دقت و عملکرد بهتری دارند. چودری و همکاران (۲۰۲۵) با استفاده از رویکردهای ترکیبی کوانتومی - کلاسیکی پیش‌بینی روندهای بازارهای مالی را بررسی کردند. نتایج نشان می‌دهند یادگیری کوانتومی به مدل‌سازی مالی کمک می‌کند و بینش‌هایی در مورد نقش عملی منابع کوانتومی در تحلیل سری‌های زمانی فراهم می‌کند. ژو و همکاران (۲۰۲۵) با بهره‌گیری از مدل‌های سه عاملی، پنج عاملی فاما- فرنچ، چهار عاملی

۱. شبکه کلاسی به عنوان یک دستگاه اندازه‌گیری قابل یادگیری عمل می‌کند که از ماتریس چگالی خروجی، بیشترین قیمت رسیده به یک دارایی برای یک زمان خاص را استنباط می‌کند.

2. Kea et al.

3. Mahmood et al.

4. Xu et al.

۵. Quantum Gramian Angular Field:

میدان زاویه‌ای گرمیان کوانتومی روشی کوانتومی برای تبدیل سری‌های زمانی مانند بازدهی سهام به تصاویر دوبعدی است که با بهره‌گیری از مدارهای کوانتومی، روابط زاویه‌ای داده‌ها را محاسبه می‌کند.

کاره‌ارت و حافظه بلندمدت کوتاه‌مدت بازدهی سهام در سه بخش تولیدی، فناوری پیشرفته و سایر بخش‌ها در بازار سهام ایالات متحده آمریکا را بررسی کردند. نتایج نشان می‌دهند مدل پنج عاملی فاما- فرنچ برای پیش‌بینی بازدهی سهام در سه بخش تولیدی، فناوری پیشرفته و سایر بخش‌ها اعتبار و توانایی بالاتری دارد. همچنین، مدل حافظه بلندمدت کوتاه‌مدت توانایی شناسایی عوامل موثر بر بازده برخی از صنایع را دارد و بازدهی سهام را با دقت بهتر و بالاتری پیش‌بینی می‌کند.

سود و بوشان^۱ (۲۰۲۵) با بهره‌گیری از رویکرد طبقه‌بند جنگل تصادفی، پیش‌بینی نماد بازده روز بعد را در بازارهای مالی مورد بررسی قرار دادند. یافته‌ها نشان می‌دهند استفاده از مدل‌های یادگیری ماشین تحلیل و پیش‌بینی دقیق‌تر و غنی‌تر در بازارهای مالی دارند. علاوه‌براین، بررسی داده‌های ورودی جایگزین مانند متغیرهای اقتصاد کلان می‌تواند به بهبود ارزیابی عملکرد مدل‌های یادگیری ماشین کمک کند. دای و همکاران^۲ (۲۰۲۵) برای پیش‌بینی بازدهی آتی بازار سهام، مدل جدیدی بر اساس الگوی شمع ژاپنی و محاسبه تفاضل بین سایه‌ی بالایی و پایینی^۳ طراحی کردند. نتایج حاکی است تفاضل بین سایه‌ی بالایی و پایینی از نظر عملکرد پیش‌بینی درون‌نمونه‌ای و برون‌نمونه‌ای، نسبت به پیش‌بینی کننده‌ی بنیادی معروف بهتر و دقیق‌تر عمل می‌کند. علاوه‌براین، اطلاعات مکمل مفیدی برای پیش‌بینی بازدهی سهام فراهم می‌کند که استفاده از این اطلاعات می‌تواند سود قابل توجهی برای سرمایه‌گذاران در پی داشته باشد. بوئپان و سارا کورن^۴ (۲۰۲۵) با استفاده از شبکه‌های عصبی عمیق و فرآیند آماده‌سازی داده شامل نمونه‌برداری براساس دلار^۵، برچسب‌گذاری براساس اسکن روند^۶ و تقریب تجمعی قطعه‌ای^۷ بازدهی سهام شرکت‌های اپل، گوگل، مایکروسافت و اینتل را بررسی کردند. یافته‌ها نشان می‌دهند مدل‌هایی که براساس دلار و برچسب‌گذاری عمل می‌کنند از دقت و قابلیت تعمیم بالایی در پیش‌بینی بازدهی سهام برخوردار هستند. وو و همکاران^۸ (۲۰۲۵) با ترکیب حافظه

-
1. Sood & Bhushan
 2. Dai et al.
 3. Upper-Lower Shadow Difference
 4. Boonpan & Sarakorn
 5. Dollar Bar Sampling
 6. Trend Scanning Labeling
 7. Piecewise Aggregate Approximation
 8. Wu et al.

بلندمدت کوتاهمدت و شبکه عصبی پیچشی یک مدل نوآورانه از شبکه مولد تخصصی^۱ برای پیش‌بینی بازدهی بازار سهام در کشور چین را طراحی کردند. نتایج نشان می‌دهند مدل شبکه مولد تخصصی نسبت به مدل‌های معیار دقت و عملکرد بهتری در پیش‌بینی بازدهی بازار سهام دارند. علاوه بر این، با اضافه کردن متغیرهای کلان اقتصادی به داده‌های آموزشی، مدل شبکه مولد تخصصی در برابر نوسانات اقتصادی پایداری خود را حفظ می‌کند.

راعی و همکاران (۱۳۸۲) با استفاده از شبکه‌های عصبی مصنوعی و مدل خطی عاملی رفتار بازده بازار سهام بورس و اوراق بهادار تهران را پیش‌بینی کردند. نتایج پژوهش حاکی است شبکه‌های عصبی مصنوعی در پیش‌بینی بازدهی سهام عملکرد بهتری دارند. ذوالفقاری و همکاران (۱۳۹۸) با استفاده از مدل‌های شبکه عصبی بازگشتی مبتنی بر حافظه کوتاهمدت و بلندمدت، الگوهای گارچ^۲ و گارچ نمایی، بازدهی روزانه شاخص کل بورس اوراق بهادار تهران را بررسی کردند. نتایج حاکی است در پیش‌بینی بازدهی بازار بورس اوراق بهادار مدل‌های ترکیبی نسبت به مدل‌های ساده (شبکه عصبی بازگشتی کوتاهمدت و بلندمدت، گارچ و گارچ نمایی) دقت و عملکرد بهتری دارند. همچنین، در مدل‌های ترکیبی خطای پیش‌بینی کاهش یافته است. سهرابی و همکاران (۱۴۰۲) با بهره‌گیری از الگوریتم‌های یادگیری عمیق و یادگیری ماشین شاخص کل بورس اوراق بهادار تهران را طی دوره زمانی ۱۳۹۹-۱۳۹۲ بررسی کردند. نتایج حاکی است شبکه عصبی بازگشتی حافظه بلندمدت کوتاهمدت در افق‌های زمانی ۱، ۳ و ۶ روزه نسبت به سایر مدل‌ها دقت بهتری را دارا می‌باشد. خلفی و همکاران (۱۴۰۲) با استفاده از شبکه‌های عصبی پویا و ایستا بازدهی سهام بورس اوراق بهادار تهران طی دوره زمانی ۱۳۹۱-۱۴۰۰ را بررسی کردند. یافته‌ها نشان می‌دهند شبکه‌های عصبی پویا نسبت به مدل‌های شبکه عصبی ایستا در پیش‌بینی بازدهی سهام از دقت بالاتری برخوردار است. صراف و همکاران (۱۴۰۳) با استفاده از الگوهای کلاسیک، رگرسیون‌های غیرساختاری، رگرسیون‌های بیزین با پارامتر متغیرهای زمانی، مدل‌های تبدیل موجک گسسته و پیوسته، رویکردهای فرا ابتکاری، شبکه عصبی مصنوعی ساده و عمیق، دیفرانسیل تصادفی و کوانتوم مالی، مدلی جهت پیش‌بینی بازده سهام در بازه زمانی ۱۳۹۷-۱۴۰۱ برای بازار سرمایه تهران را طراحی و بررسی کردند. نتایج نشان می‌دهد در بازه زمانی کوتاهمدت ۱ روزه، مدل‌های میانگین‌گیری بیزین؛ در میان مدت ۱۶ روزه، مدل‌های کوانتومی مالی و در بلندمدت ۳۲ روزه، مدل‌های موجک پیوسته

1. Generative Adversarial Network

2. GARCH

و گسسته دقت و عملکرد بهتر و دقیق‌تری دارند. مرادی و همکاران (۱۴۰۴) با استفاده از الگوریتم‌های یادگیری عمیق و یادگیری ماشین و همچنین، داده‌های هفتگی ۲۰۰ شرکت منتخب در بازار سهام، اطلاعات مربوط به متغیرهای نقدینگی، نوع صنعت، اندازه و سودآوری شرکت‌ها بازده بازار سهام ایران را طی دوره زمانی ۱۳۹۹-۱۳۹۵ بررسی کردند. نتایج نشان می‌دهد الگوی حافظه بلندمدت کوتاه‌مدت از نظر معیارهای ضریب تعیین و ریشه میانگین مربعات خطا نسبت به مدل‌های رقیب عملکرد بهتری را دارا است. همچنین، در ایجاد نوسان در بازار سهام به ترتیب پیشامدهای سیاسی، اقتصادی و اجتماعی بیش‌ترین نقش را دارا هستند. صحرایی و همکاران (۱۴۰۴) با بهره‌گیری از رویکرد شبکه عصبی خودبازگشتی غیرخطی با متغیرهای برون‌زا، بهینه‌سازی پرتفوی مبتنی بر پیش‌بینی در بورس اوراق بهادار تهران در بازه زمانی ۱۳۹۹ - ۱۴۰۰ را بررسی کردند. نتایج نشان می‌دهد شبکه عصبی خودبازگشتی غیرخطی در مقایسه با رویکردهای رقیب، از دقت بالاتری در پیش‌بینی بازدهی بازار سهام برخوردار است.

مرور پیشینه و ادبیات موضوع نشان می‌دهد پژوهشگران در حوزه پیش‌بینی بازدهی بازار سهام از طیف گسترده‌ای از روش‌ها از جمله؛ الگوهای کلاسیک اقتصاد سنجی، الگوهای یادگیری ماشین و یادگیری عمیق استفاده کرده‌اند. اگرچه این مدل‌ها در بسیاری از مطالعات عملکرد قابل قبولی داشته‌اند؛ اما با محدودیت‌هایی از جمله ناتوانی در مدل‌سازی پویایی‌های غیرخطی پیچیده، حساسیت به نویز و ضعف در واکنش به ساختارهای پرنوسان بازار مالی مواجه هستند. با توجه به ماهیت غیرایستا و پرتلاطم بازار سهام استفاده از مدل‌هایی با قدرت تعمیم‌دهی عمیق‌تر و استخراج الگوهای نهفته ضرورتی انکار ناپذیر است.

به‌همین منظور، در پژوهش حاضر، با هدف رفع بخشی از کاستی‌های روش‌های متعارف از الگوریتم‌های یادگیری عمیق کوانتومی برای پیش‌بینی بازدهی بازار سهام استفاده شده است. ویژگی‌های بنیادین رایانش کوانتومی همچون برهم‌نهی و درهم‌تنیدگی، قابلیت نمایش و پردازش هم‌زمان حالات متعدد و کشف ساختارهای پنهان در داده‌های پرتلاطم را فراهم می‌کند؛ موضوعی که در مدل‌های کلاسیک و حتی بسیاری از مدل‌های یادگیری عمیق متداول به‌طور کامل محقق نمی‌شود. بر این اساس، انتظار می‌رود مدل‌های یادگیری عمیق کوانتومی با بهره‌گیری از فضای حالت گسترده‌تر و معماری‌های محاسباتی متفاوت، توانایی بالاتری در پیش‌بینی بازدهی بازار سهام ارائه دهند.

روش‌شناسی پژوهش

جامعه و نمونه آماری

پژوهش حاضر از روش کتابخانه‌ای و اسنادی برای جمع‌آوری اطلاعات و داده‌های مورد نیاز استفاده می‌کند. جامعه آماری شامل شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است و داده‌های مورد استفاده از سایت کدال^۱ استخراج شده‌اند. برای اجرای مدل، تجزیه و تحلیل داده‌ها و پیاده‌سازی الگوهای مختلف مدل‌سازی از نرم‌افزار پایتون (نسخه ۳,۱۲)^۲ استفاده می‌شود. در این پژوهش، نخست بازدهی بازار سهام با استفاده از داده‌های شاخص قیمت وزنی-ارزشی محاسبه می‌گردد. سپس، به منظور پیش‌بینی و تحلیل روندهای بازار سهام، الگوریتم‌های مختلف مدل‌سازی بر روی داده‌ها اعمال می‌شود. این الگوریتم‌ها شامل مدل‌های کلاسیک سری‌های زمانی، الگوریتم‌های یادگیری ماشین، مدل‌های یادگیری عمیق و یادگیری عمیق کوانتومی هستند. در مرحله بعد، بر اساس معیارهای خطا عملکرد الگوها در مدل‌سازی مقایسه و بررسی می‌شوند. سپس، اعتبار نتایج برای اطمینان از توانایی هر مدل در شناسایی الگوها و پیش‌بینی بازدهی بازار مورد ارزیابی قرار می‌گیرد. در نهایت، با استفاده از الگوی کارآ، بازده بازار سهام پیش‌بینی می‌شود.

محاسبه بازده بازار سهام

هدف پژوهش حاضر پیش‌بینی بازده بازار سهام در ایران است. برای این منظور نخست، بازده بازار سهام محاسبه و سپس برای مدل‌سازی و پیش‌بینی آن الگوی پژوهش و برخی از الگوهای رقیب که در مطالعات مختلف ارزیابی و استفاده می‌شوند، معرفی می‌گردند. بازده بازار سهام بر اساس معادله (۱) محاسبه می‌شود.

$$R_t = \log\left(\frac{p_t}{p_{t-1}}\right) \quad (1)$$

که در آن R و P به ترتیب نشان‌دهنده بازدهی و شاخص قیمت وزنی-ارزشی بورس اوراق بهادار تهران هستند.

مدل‌های پایه سری زمانی

میانگین متحرک مرتبه اول (MA) و خود رگرسیون مرتبه اول (AR) جزو مدل‌های پایه سری زمانی می‌باشند. این مدل‌ها به خوبی می‌توانند وابستگی‌های کوتاه‌مدت داده‌ها را شناسایی کنند. مدل

1. <https://www.codal.ir/>

2. Python 3.12

AR بر اساس مقادیر گذشته متغیر؛ پیش‌بینی انجام می‌دهد، در حالی که مدل MA از ترکیب شوک‌ها و خطاهای گذشته برای برآورد استفاده می‌کند. به همین دلیل هر دو مدل در پیش‌بینی نوسانات کوتاه‌مدت بازار سهام کارآمد هستند و درک مناسبی از پویایی‌های لحظه‌ای بازار ارائه می‌دهند. اما با این حال، هر دو مدل با محدودیت‌هایی روبرو هستند. این مدل‌ها بر پایه فرض ایستایی، خطی بودن و نرمال بودن داده‌ها بنا شده‌اند. در حالی که داده‌های مالی، به‌ویژه در بازار سهام، اغلب غیرخطی، ناپایستا و با شوک‌های شدید مواجه هستند. بنابراین، MA و AR در توضیح رفتارهای پیچیده مانند خوشه‌بندی نوسانات، جهش‌های ناگهانی، یا روندهای بلندمدت کارایی و دقت کافی ندارند. به همین دلیل، در کاربردهای واقعی معمولاً این مدل‌ها به‌صورت ترکیبی مثل ARIM یا در کنار روش‌های پیشرفته‌تر مانند الگوریتم‌های یادگیری ماشین استفاده می‌شوند تا ضعف‌هایشان جبران شود.

مدل‌های یادگیری ماشین

رگرسیون بردار پشتیبان^۱

رگرسیون بردار پشتیبان اصولی مشابه ماشین بردار پشتیبان دارد. با این تفاوت که متغیر پاسخ یک مقدار پیوسته است. همچنین، در رگرسیون بردار پشتیبان به جای یافتن ابر صفحه به دنبال یافتن یک تابع رگرسیون خطی است که در معادله (۱) تعریف شده است. برای این منظور یک آستانه خطا (ϵ) تعریف می‌شود که در معادله (۲) مینیم می‌شود و به عنوان تابع زیان در نظر گرفته می‌شود. در واقع رگرسیون بردار پشتیبان در تلاش است تا (ϵ) در معادله (۲) و $\|w\|^2$ در معادله (۳) را مینیم کند (هنریکه، سوبریرو و کیمورا^۲، ۲۰۱۸).

$$f(x, y) = w^T x + b \quad (۲)$$

$$|y - f(x, w)|_\epsilon = \begin{cases} 0, & \text{case } |y - f(x, w)| \leq \epsilon \\ |y - f(x, w)| - \epsilon, & \text{otherwise} \end{cases} \quad (۳)$$

$$R = \frac{1}{2} \|w\|^2 + c \left(\sum_{i=1}^N |y_i - f(x_i, w)|_\epsilon \right) \quad (۴)$$

$$R = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^N (\zeta_i + \zeta_i^*) \quad (۵)$$

-
1. Support Vector Regression
 2. Henrique, Sobreiro & Kimura

$$(w^T x_i + b) - y_i \leq \varepsilon + \zeta_i \quad (۶)$$

$$y_i - (w^T x_i + b) - y_i \leq \varepsilon + \zeta_i^* \quad (۷)$$

جنگل تصادفی^۱

الگوریتم جنگل تصادفی یک مدل غیر خطی است که چندین درخت تصمیم را در قالب یک جنگل ترکیب می‌کند. نمونه‌برداری تصادفی و رای‌گیری اکثریت دو اصل مهم در رویکرد جنگل تصادفی است. بر اساس نمونه برداری تصادفی، برای هر درخت تصمیم، مجموعه‌ای از داده‌های آموزشی به صورت تصادفی از کل نمونه‌ها انتخاب می‌شوند. هر درخت تصمیم‌گیری به طور مستقل پیش‌بینی را انجام می‌دهد و جنگل تصادفی این پیش‌بینی‌ها را از طریق رای‌گیری ترکیب می‌کند. به این صورت که بیش‌ترین رای، پیش‌بینی نهایی را تعیین می‌کند. در واقع استفاده از این رویکرد از بیش‌برازش یک درخت تصمیم‌گیری منحصر به فرد جلوگیری می‌کند. در نهایت، رای اکثریت به عنوان نتیجه طبقه‌بندی نمونه در نظر گرفته می‌شود. همچنین، نسبت تعداد نمونه‌های اشتباه طبقه‌بندی شده به کل نمونه‌ها به عنوان نرخ خطای برون کیسه‌ای^۲ جنگل تصادفی گزارش می‌شود (خایدیم، ساها و دی، ۲۰۱۶.^۳).

مدل یادگیری عمیق کلاسیک

حافظه بلندمدت کوتاه‌مدت^۴

حافظه بلندمدت کوتاه‌مدت یک نوع خاص از شبکه عصبی بازگشتی است و از طریق بهبود طراحی، مشکل وابستگی‌های بلندمدت را کاهش می‌دهد. به همین دلیل، در پردازش داده‌های سری زمانی عملکرد مناسب و قابل قبولی دارد. همچنین، هسته اصلی حافظه بلندمدت کوتاه مدت در وضعیت سلول^۵ و ساختار دروازه‌ها^۶ به صورت نهفته قرار دارد (کریشن و

-
1. Random Forest
 2. Out-of-Bag Error
 3. Saha & Dey Khaidem
 4. Long Short-Term Memory
 5. Cell State
 6. Gate Structure

می‌هوب^۱، ۲۰۲۵). روش استخراج ویژگی در مدل کلاسیک حافظه بلندمدت کوتاه‌مدت به صورت زیر نشان داده شده است:

$$F_t = \sigma(W_F \cdot [h_{t-1}, X_t]) + b_F \quad (۸)$$

$$I_t = \sigma(W_I \cdot [h_{t-1}, X_t]) + b_I \quad (۹)$$

$$C_t = \tanh(W_C \cdot [h_{t-1}, X_t]) + b_C \quad (۱۰)$$

$$C_t = f_t * C_{t-1} + I_t * C_t \quad (۱۱)$$

$$O_t = \tanh(W_O \cdot [h_{t-1}, X_t]) + b_O \quad (۱۲)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (۱۳)$$

F_t, I_t, C_t و O_t به ترتیب دروازه فراموشی، دروازه ورودی، وضعیت سلول پیشنهادی، وضعیت سلول و دروازه خروجی در لحظه t را نشان می‌دهند؛ W_F, W_I, W_C و W_O ماتریس‌های وزنی مورد استفاده، σ تابع سیگموئید و در نهایت b_F, b_C, b_O و b_I مقادیر بایاس هستند.

شبکه عصبی بازگشتی با واحد دروازه دار^۲

واحد بازگشتی دروازه‌دار یک مدل بهبودیافته از شبکه عصبی بازگشتی است. این شبکه از دروازه بازنشانی^۳ و دروازه به‌روزرسانی^۴ تشکیل شده است (مینیه، سوارت و اویدو^۵، ۲۰۲۴). روش استخراج ویژگی در شبکه عصبی بازگشتی با واحد دروازه‌دار به صورت زیر می‌باشد:

$$Z_t = \sigma(W_Z \cdot ([h_{t-1}, X_t])) \quad (۱۴)$$

$$r_t = \sigma(W_t \cdot ([h_{t-1}, X_t])) \quad (۱۵)$$

$$h_t = \tanh(W_h \cdot r_t * h_{t-1}, X_t) \quad (۱۶)$$

1. Krichen & Mihoub.

2. Gated Recurrent Unit

3. Reset Gate

4. Update Gate

5. Mienye, Swart & Obaido

$$h_t = (1 - z_t) * h_{t-1} + z_t * h_t \quad (17)$$

h_t و r_t, z_t به ترتیب دروازه به روزرسانی، دروازه بازنشانی و حالت پیشنهادی لحظه t را نشان می دهند؛ W_r, W_z و W_h نیز ماتریس های وزنی مورد استفاده هستند.

پرسپترون چندلایه یا شبکه عصبی کاملاً متصل^۱

شبکه عصبی کاملاً متصل از چارچوب های توسعه موازی برای پیش بینی متغیرهای هدف استفاده می کند. پیش بینی از طریق پردازش نورون ها یا عناصر لایه های ورودی، پنهان و خروجی که با وزن های ارتباطی^۲ به هم متصل هستند انجام می شود. همچنین، تابعی که فعالیت نورون را تعیین می کند باید قابل تفکیک و غیر کاهشی باشد تا یک غیر خطی ملایم^۳ ایجاد شود. تابع جمع برای ارائه خروجی نورون های پنهان در شبکه عصبی کاملاً متصل به صورت زیر بیان می شود:

$$I_j = \sum_{i=1}^{n_o} W_{ij} Y_i + \alpha_j \quad (18)$$

$$Y_j = f(I_j) = (1 + e^{-x_j})^{-1} \quad (19)$$

α_j مقدار بایاس نورون j در لایه پنهان است؛ W_{ij} مقدار وزن نورون ورودی i و نورون خروجی j است؛ I_j ورودی نورون j در لایه پنهان را نشان می دهد و در نهایت Y_j خروجی نورون j است. خروجی لایه نهایی به صورت زیر بیان می شود:

$$O_t^k = \sum_{j=1}^{n_1} W_{jk} Y_j + \alpha_k \quad (20)$$

W_{ij} وزن بین نورون j در لایه پنهان و نورون k در لایه خروجی است؛ n_1 تعداد نورون های لایه پنهان و O_t^k خروجی نورون k در لایه خروجی می باشند.

مبانی محاسبات کوانتومی

کیوبیت

کیوبیت کوچک ترین واحد کوانتومی است. برخلاف بیت های کلاسیک، کیوبیت ها به صورت همزمان در حالتی بین ۰ و ۱ قرار می گیرند که نشان دهنده اصل برهم نهی کوانتومی

-
1. Multi-Layer Perceptron
 2. Connection Weights
 3. Soft Non-linearity

است. ویژگی دیگر، کیوبیت درهم تنیدگی است به این معنا که می‌توانند به صورت متقابل به هم وابسته باشند و بر یکدیگر اثرگذار باشند. مقدار یک کیوبیت با استفاده از یک بردار ستونی از دامنه‌های احتمالی نمایش داده می‌شود. این دامنه‌ها می‌توانند منفی باشند اما، مجموع مربع همه دامنه‌ها همیشه برابر یک است. برای قرار دادن کیوبیت در حالت برهم نهی بین ۰ و ۱ می‌توان از دروازه هادامارد^۱ استفاده کرد. سایر دروازه‌های واحدی^۲ دامنه‌های احتمال کیوبیت‌ها را تغییر می‌دهند و با ایجاد برهم‌نهی‌های مختلف، امکان نمایش داده‌های بیش‌تر را فراهم می‌کنند.

حالت ضربی و درهم تنیدگی کوانتومی

زمانی که چند کیوبیت در یک مدار کوانتومی قرار می‌گیرند، حالت کل سیستم به صورت یک بردار ستونی در فضای هیلبرت ترکیبی نمایش داده می‌شود. برای مثال، در یک سیستم دو کیوبیتی، چهار حالت پایه وجود دارد که هر کدام با احتمال مشخصی قابل اندازه‌گیری هستند. اگر حالت برهم‌نهی سیستم به گونه‌ای باشد که هر کیوبیت به‌طور مستقل در ترکیب کلی سهم داشته باشد و بین آن‌ها وابستگی متقابل وجود نداشته باشد، این حالت به عنوان حالت ضربی شناخته می‌شود و رفتاری شبیه بیت‌های کلاسیک دارد. در مقابل، اگر حالت ترکیبی سیستم قابل تفکیک به حاصل ضرب حالت‌های منفرد نباشد، کیوبیت‌ها در وضعیت درهم تنیدگی قرار می‌گیرند؛ حالتی منحصر به فرد در مکانیک کوانتومی که ویژگی‌های غیر کلاسیک و تعاملات پیچیده میان کیوبیت‌ها را نشان می‌دهد (آیشواریا، ونکاستان و پرابهاوان^۳، ۲۰۲۵).

دروازه کوانتومی^۴

برای انجام محاسبات کوانتومی انواع مختلفی از دروازه‌های کوانتومی مانند؛ دروازه X ، دروازه هادامارد، دروازه Z و دروازه کنترل استفاده می‌شوند. هر یک از این دروازه‌ها عملکرد خاص و ویژه خود را دارند و تبدیلات متفاوتی بر روی کیوبیت‌ها اعمال می‌کنند. از نظر ریاضی،

1. Hadamard Gate

2. unitary gates

3. Aishwarya, Venkatesan & Prabhavathy

4. Quantum Gate

هر دروازه کوانتومی با یک ماتریس واحدی^۱ نمایش داده می‌شود که ضرب آن در مزدوج مختلط خود ماتریس واحد را تولید می‌کند. این ویژگی نشان دهنده برگشت پذیری عملیات انجام شده توسط دروازه کوانتومی است (آیشواریا و همکاران^۲، ۲۰۲۵).

مدل یادگیری عمیق کوانتومی

پیش‌بینی بازدهی بازار سهام نوعی داده معاملاتی با فرکانس بالا است که دارای ویژگی‌های سری زمانی می‌باشد. بنابراین، در این پژوهش یک مدل حافظه بلندمدت کوتاه‌مدت کوانتومی برای پیش‌بینی بازدهی بازار سهام استفاده می‌شود. تفاوت اصلی بین حافظه بلند مدت کوتاه کوانتومی و کلاسیک در نوع شبکه است. مدل حافظه بلندمدت کوتاه‌مدت کوانتومی از مدارهای متغیر کوانتومی (VQC) برای محاسبات استفاده می‌کند. اما در حافظه بلندمدت کوتاه‌مدت بر پایه شبکه‌های عصبی خطی عمل می‌کند. در طراحی مدل حافظه بلندمدت کوتاه‌مدت، رفتار سلول حافظه بلندمدت با استفاده از گیت‌های کوانتومی باز تولید می‌شود. هر جعبه VQC مشابه یک گیت سلول حافظه بلندمدت کوتاه‌مدت است. به طور خاص: VQC1 تا VQC4 به ترتیب متناظر با گیت فراموشی، ورودی، به‌روزرسانی و خروجی هستند VQC5 برای تبدیل حالت سلول c_t به حالت مخفی h_t استفاده می‌شود. VQC6 برای تصحیح بیشتر حالت سلول c_t و تبدیل آن به خروجی y_t به کار می‌رود. در نهایت، خروجی y_t از اندازه‌گیری‌های گرفته‌شده در انتهای هر VQC استخراج می‌شود. این اندازه‌گیری‌ها مقادیر امید ریاضی برای هر کیوبیت درگیر را ارائه می‌دهند. به‌طور اختیاری، این مقادیر می‌توانند طی پردازش پسین کلاسیک از توابع فعال‌سازی غیرخطی عبور کنند و خروجی نهایی را شکل دهند.

$$V_t = [h_{t-1} \cdot X_t], \quad (22)$$

$$f_t = \sigma(VQC_1(v_t)), \quad (21)$$

$$i_t = \sigma(VQC_2(v_t)), \quad (23)$$

$$\tilde{c}_t = \tanh(VQC_3(v_t)), \quad (24)$$

1. Unitary Matrix

2. Aishwarya et al.

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t, \quad (25)$$

$$o_t = \sigma(VQC_4(v_t)), \quad (26)$$

$$h_t = VQC_5(o_t * \tanh(c_t)), \quad (27)$$

$$y_t = VQC_6(h_t), \quad (28)$$

تمامی VQC ها در معماری حافظه بلندمدت کوتاه‌مدت کوانتومی فرموله و در سه بلوک گیت فراموشی، گیت‌های ورودی و بروزرسانی و گیت خروجی قرار می‌گیرند (کیا و همکاران، ۲۰۲۴).

گیت فراموشی^۱


گیت فراموشی در حافظه بلندمدت کوانتومی با استفاده از VQC1 پیاده‌سازی می‌شود. در این بخش، حالت مخفی h_{t-1} با ورودی x_t ترکیب و یک بردار f_t تولید می‌شود که مقادیر آن بین ۰ تا ۱ قرار می‌گیرد. این بردار تعیین می‌کند که کدام عناصر از حالت سلول قبلی c_{t-1} حفظ شوند و کدام فراموش شوند. در نتیجه، گیت فراموشی مسئول مدیریت حافظه بلندمدت، حفظ یا حذف اطلاعات گذشته است.

گیت‌های ورودی و به‌روزرسانی^۲

گیت‌های ورودی و به‌روزرسانی تعیین می‌کنند چه اطلاعات جدیدی به حالت سلول اضافه شوند. ابتدا VQC2 ورودی ترکیبی V_t را پردازش و خروجی آن از طریق تابع سیگموید عبور می‌کند تا مشخص شود کدام مقادیر باید وارد حالت سلول شوند. همزمان، VQC3 همان ورودی ترکیبی را پردازش کرده و با استفاده از تابع تانژانت هیپربولیک یک کاندید حالت سلول جدید C_t تولید می‌کند. سپس خروجی VQC2 به‌صورت عنصر به عنصر در C_t ضرب می‌کند و بردار حاصل برای بروزرسانی حالت سلول C_t استفاده می‌شود. این مکانیزم باعث می‌شود حافظه بلندمدت کوتاه‌مدت بتواند اطلاعات جدید را به شکل کنترل شده به حافظه بلندمدت اضافه کند.

1. Forget Gate

2. Input & Update Gates



نمودار ۱: ساختار مدل یادگیری عمیق کوانتومی (QLSTM)

گیت خروجی^۱

گیت خروجی با استفاده از VQC4 پردازش می‌شود. ابتدا ورودی ترکیبی V_t از طریق تابع سیگموید عبور داده می‌شود تا اهمیت مقادیر موجود در حالت سلول c_t مشخص شود. سپس، حالت سلول از طریق تابع تانژانت هیپربولیک تغییر یافته و در خروجی VQC4 ضرب می‌شود. خروجی حاصل می‌تواند به صورت اختیاری توسط VQC5 پردازش شود تا حالت مخفی h_t تولید شود و یا توسط VQC6 پردازش شود تا خروجی y_t تولید گردد. از آنجا که ابعاد حالت سلول، حالت مخفی و خروجی معمولاً یکسان نیستند، VQC5 و VQC6 برای تبدیل ابعاد c_t به h_t و y_t استفاده می‌شوند تا اطمینان حاصل شود که جریان اطلاعات بین گیت‌ها به درستی انجام می‌شود. نمودار ۱ به صورت خلاصه ساختار مدل یادگیری عمیق را نشان می‌دهد.

1. Output Gate

معیارهای ارزیابی مدل

در پژوهش حاضر برای ارزیابی دقت و کارآیی تخمین، از معیارهای MSE، RMSE، Theil's U برای ارزیابی نتایج استفاده می‌شود که به صورت زیر بیان می‌شوند (دتهاامروننگ، کلاننگ‌بون‌رئوننگ، چانسانام و داسری^۱، ۲۰۲۵):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (29)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (30)$$

$$\text{Theil's } U = \sqrt{\frac{\sum (y_t - \tilde{y}_t)^2}{\sum y_t^2}} \quad (31)$$

ارزیابی معناداری تفاوت خطاهای پیش‌بینی مدل‌ها

آزمون دایبولد - ماریانو^۲

آزمون دایبولد - ماریانو تفاوت‌های معنادار در دقت پیش‌بینی میان مدل‌های مختلف را بر اساس تحلیل کمی تشخیص می‌دهد (کورونئو و ایاکونه^۳، ۲۰۲۵) و به صورت زیر بیان می‌شود:

$$DM = \frac{\bar{d}}{\sqrt{\frac{2\pi f \bar{d}(0)}{T}}} \rightarrow N(0,1) \quad (32)$$

$$\bar{d} = L(e_{1,t}) - L(e_{2,t}) \quad (33)$$

$\bar{d}$ میانگین نمونه‌ای تفاضل تابع زیان دو مدل پیش‌بینی است. همچنین، $2\pi f \bar{d}$ یک برآوردگر همگرا از واریانس مجانب $\bar{d}$ است. فرضیه صفر درباره برابری دقت پیش‌بینی به صورت $H_0 = E[d_t] = 0$ نشان داده می‌شود و آماره DM به توزیع نرمال همگرا است. برای این اساس، اگر $|DM| > 1/96$ باشد، فرضیه صفر در سطح معنی‌داری ۵ درصد رد می‌شود که به معنای اعتبار تفاوت خطای پیش‌بینی الگوها است و در صورتی که $|DM| \leq 1/96$ باشد فرضیه صفر در سطح معناداری ۵ درصد رد نمی‌شود.

1. Detthamrong, Klangbunrueang, Chansanam, & Dasri

2. Diebold-Mariano Test

3. Coroneo & Iacone

آزمون ویلکاکسون با رتبه‌های نشانه دار^۱

آزمون ویلکاکسون با رتبه‌های نشانه‌دار روی اختلاف خطاهای پیش‌بینی دو مدل محاسبه می‌شود. ابتدا برای هر دوره زمانی t در مجموعه داده‌ها، خطای پیش‌بینی هر دو مدل محاسبه و اختلاف آن‌ها به صورت زیر به دست می‌آید:

$$d_i = |e_{1,i}| - |e_{2,i}| \quad (34)$$

سپس رتبه‌های قدرمطلق اختلاف خطاها محاسبه می‌شود و براساس اینکه کدام مدل دارای خطای پیش‌بینی کمتر است به رتبه‌ها علامت مثبت یا منفی اختصاص داده می‌شود. در نهایت، با استفاده از مجموع رتبه‌های مثبت و منفی، آماره ویلکاکسون و سطح احتمال متناظر آن محاسبه می‌شود تا معناداری آماری تفاوت خطاهای پیش‌بینی دو مدل آزمون و ارزیابی شود (پرخودکو و شیلیاچوک^۲، ۲۰۲۵).

یافته‌های پژوهش

توصیف داده‌ها

در پژوهش حاضر برای محاسبه بازدهی بازار سهام تهران، از شاخص قیمت وزنی - ارزشی با تواتر روزانه استفاده شد که بازه زمانی دوازدهم بهمن سال ۱۳۹۴ تا پانزدهم مهر ماه سال ۱۴۰۴ شمسی را در بر می‌گیرد. برای مدل‌سازی و پیش‌بینی، ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای آزمون مدل استفاده می‌شوند. بنابراین، داده‌های بازه زمانی ۱۳۹۴ تا بیست و هفتم فروردین ماه سال ۱۴۰۲ به منظور آموزش و داده‌های ۲۸ فروردین سال ۱۴۰۲ تا ۱۵ مهر سال ۱۴۰۴ به عنوان بازه آزمون مدل مورد استفاده قرار می‌گیرند. جدول (۱) آماره‌های توصیفی داده‌ها را به اختصار گزارش می‌کند.

جدول ۱. آماره‌های توصیفی بازدهی بازار سهام

ویژگی آماری	بازدهی سهام
میانگین	۰/۰۰۱۴۵۳
میانه	۰/۰۰۰۵۴۴
انحراف معیار	۰/۱۳۳۷۵
حداقل	-۰/۱۰۱۲۹۴
حداکثر	۰/۱۳۳۹۲۴

1. Wilcoxon Signed-Rank Test

2. Perekhodko & Ślepaczuk

ویژگی آماری	بازدهی سهام
کشیدگی	۳/۰۵۵۶۸
چولگی	-۰/۰۰۱۵۴۴

منبع: یافته‌های پژوهش

همان‌گونه که مشاهده می‌شود، انحراف معیار نسبت به میانگین تفاوت قابل توجهی دارد که نشان می‌دهد هرچند به‌طور متوسط بازدهی بازار در دوره مورد بررسی مثبت می‌باشد، اما، با نوسانات شدید و ریسک بالا همراه می‌باشد. به بیان دیگر، روزهایی با سودهای بزرگ، میانگین را افزایش داده‌اند، اما رفتار کلی بازار نوسانی و غیرقابل پیش‌بینی باقی مانده است. علاوه بر این، چولگی نزدیک به صفر و کشیدگی کمی بالاتر از توزیع نرمال نشان می‌دهد که توزیع بازدهی‌ها تقریباً متقارن است، اما با دم‌های سنگین‌تر، به این معنا که احتمال وقوع رویدادهای شدید مانند جهش‌ها یا سقوط‌های ناگهانی کمی بیشتر از توزیع نرمال است. این یافته‌ها بر ضرورت بهره‌گیری از استراتژی‌های مدیریت ریسک قوی و به کارگیری مدل‌های پیشرفته پیش‌بینی برای مواجهه با نوسانات شدید بازار تأکید دارد.

نتایج مدل‌سازی بازدهی بازار سهام

به منظور پیش‌بینی بازدهی بازار سهام، نخست یافته‌های الگوهای مختلف برپایه معیارهای مختلف خطای پیش‌بینی بایکدیگر مقایسه و پس از تعیین الگوی مناسب، رفتار بازدهی سهام پیش‌بینی و با مقادیر اصلی آن مقایسه می‌شود. جدول ۲ نتایج حاصل از مدل‌سازی و پیش‌بینی بازدهی بازار سهام را براساس مدل‌های پژوهش نشان می‌دهد.

جدول ۲. نتایج پیش‌بینی مدل‌های بازدهی بازار سهام براساس معیارهای خطاها، آزمون

دایبولد - ماریانو و ویلکا کاسون

مدل	ریشه میانگین	میانگین	شاخص تایل	DM	P-V	W	P-V
ARIMA	۰/۰۰۰۲۰۷	۰/۱۴۳۹۲	۰/۸۹۵۳۱۷	-۳/۵۴	۰/۰۰۰۴۸	۷۵۵۱	۰/۰۰۱۱۴۷
LSTM	۰/۰۰۰۱۹۴	۰/۰۱۳۹۴۰	۰/۶۸۲۲۵۴	-۳/۲۴	۰/۰۰۱۳۸۶	۷۴۶۰	۰/۰۰۱۸۱۴
GRU	۰/۰۰۰۱۹۵	۰/۰۱۳۹۷۳	۰/۶۸۰۵۶۱	-۲/۸۹	۰/۰۰۴۲۵۴	۸۲۰۷	۰/۰۱۲۲۶۳
MLP	۰/۰۰۰۱۹۰	۰/۱۳۷۸۱	۰/۶۹۵۲۱۵	-۳/۶۶	۰/۰۰۰۳۲۰	۷۶۶۶	۰/۰۰۱۸۱۴
RF	۰/۰۰۰۱۹۳	۰/۰۱۳۸۹۳	۰/۷۱۰۸۲۶	-۲/۴۰	۰/۰۱۷۰۵۱	۸۳۴۱	۰/۰۱۸۵۲۲
SVR	۰/۰۰۰۲۰۲	۰/۰۱۴۲۲۳۰	۰/۶۸۱۳۲۹	-۲/۹۳	۰/۰۰۳۷۶	۷۴۲۷	۰/۰۰۰۶۸۶
QDL	۰/۰۰۰۱۸۰۸۵	۰/۰۱۳۴۴۸۲۰	۰/۴۶۳۸۱۳۶۶	-	-	-	-

منبع: یافته‌های پژوهش

معیارهای خطای پیش‌بینی حاکی‌اند مدل کلاسیک سری زمانی ARIMA نسبت به سایر الگوها عملکرد نسبتاً ضعیفی دارند که نشان‌دهنده ضعف در مدل‌سازی پیچیدگی‌های بازار سهام است. در واقع، این الگوها به دلیل ساختار خطی قادر به درک نوسانات بازار سهام نیستند. در مقابل، مدل‌های یادگیری عمیق و یادگیری ماشین عملکرد بهتری را به خود اختصاص داده‌اند. از سوی دیگر، مقایسه معیارهای خطا و شاخص تایل نشان می‌دهند که پیش‌بینی آن‌ها بسیار دقیق‌تر از مدل‌های سنتی است. در بین این گروه، کم‌ترین خطا به مدل QDL تعلق دارد و پس از آن‌ها، الگوهای RF، LSTM، GRU و SVR دارای عملکرد بهتری هستند. نتایج نشان می‌دهد که بازار سهام به دلیل ماهیت غیرخطی و پیچیده خود، توسط مدل QDL بهتر پیش‌بینی می‌شود. این مدل‌ها توانایی استخراج وابستگی‌های زمانی و الگوهای پنهان داده‌ها را دارند بنابراین، می‌توان نتیجه گرفت، گذار از مدل‌های سنتی به سمت مدل‌های عمیق کوانتومی می‌تواند تحول بزرگی در دقت پیش‌بینی بازار سهام ایجاد کند. به منظور بررسی وجود تفاوت بین خطاهای الگوها، با استفاده از رویکردهای دایبولد ماریانو و ویلکاکسون معنی‌داری تفاوت خطاهای پیش‌بینی الگوهای رقیب با روش QDL آزمون شده است. نتایج آزمون‌های دایبولد ماریانو و ویلکاکسون نشان می‌دهد فرضیه صفر برابری خطاهای پیش‌بینی مدل‌های مختلف در برابر مدل یادگیری عمیق کوانتومی در سطح معناداری ۵ درصد برای مدل‌های RF، MLP، ARIMA، LSTM، SVR و GRU رد شده است. در نتیجه تفاوت خطاهای پیش‌بینی از نظر آماری معنی‌دار است. از سوی دیگر، مقایسه گشتاورهای آماری بازدهی پیش‌بینی‌شده توسط مدل QDL شامل میانگین، میانه، انحراف معیار، چولگی و کشیدگی نشان می‌دهد که پیش‌بینی‌ها کمی بالاتر از مقادیر واقعی بوده اما نوسانات و دامنه بازدهی کاهش یافته و توزیع متقارن‌تر شده است.

جدول ۳.۳. آماره‌های توصیفی بازدهی سهام پیش‌بینی شده

ویژگی آماری	بازدهی سهام پیش‌بینی شده
میانگین	۰/۰۰۱۵۰۸
میانه	۰/۰۰۰۵۹۲
انحراف معیار	۰/۰۱۳۱۷۹
حداقل	-۰/۰۳۷۷۸۳
حداکثر	۰/۱۰۵۹۴۹
کشیدگی	۲/۳۸
چولگی	۰/۱۴۷۲۰۲

منبع: یافته‌های پژوهش

به عبارت دیگر، مدل نه تنها ویژگی‌های آماری اصلی بازدهی واقعی مانند روند مرکزی و پراکندگی را بازتولید می‌کند، بلکه پیش‌بینی‌ها از نظر ثبات، کاهش ریسک ناشی از مقادیر افراطی و نزدیکی به توزیع نرمال، عملکرد بهتری نسبت به بازار واقعی دارند. این همخوانی قوی تأکید می‌کند که مدل QDL قادر است الگوهای غیرخطی و نوسانات شدید بازار سهام را با دقت شبیه‌سازی و پیش‌بینی کند، که اعتبار عملکرد مدل و قابلیت آن در پیش‌بینی رفتار واقعی بازار را به شکل قابل توجهی تقویت می‌کند.

از سوی دیگر، بررسی عملکرد مدل QDL در مقایسه با مطالعات پیشین براساس معیار RMSE نیز حاکی است مدل QDL کم‌ترین خطای پیش‌بینی را دارد و از دقت بالاتری در پیش‌بینی بازدهی بازار سهام برخوردار است.


جدول ۴. مرور مطالعات پیشین در حوزه پیش‌بینی بازدهی بازار سهام

مطالعه	مدل مورد استفاده در پیش‌بینی	ریشه میانگین مربعات خطا
راعی و چاوشی (۱۳۸۲)	MLP	۴/۲۷
ذوالفقاری و همکاران (۱۳۹۸)	ARMAX-EGARCH-RNN-GED	۰/۰۳۳
سهرابی و همکاران (۱۴۰۲)	LSTM	۰/۲۷۸
خلفی و همکاران (۱۴۰۲)	NNARX	۰/۰۵۶۸
صحرائی و همکاران (۱۴۰۴)	NARX	۰/۰۲۴۴۹
مرادی و همکاران (۱۴۰۴)	LSTM	۰/۰۰۱۰۳۳۰۹۴
پژوهش حاضر	QDL	۰/۰۰۰۱۸۰۸۵

منبع: یافته‌های پژوهش

مدل QDL قادر است الگوها و رفتارهای بازدهی سهام را با دقت بیشتری شناسایی کند و خطای پیش‌بینی را به طور قابل توجهی کاهش دهد. برتری QDL نشان‌دهنده پایداری و قابلیت تعمیم‌پذیری بالاتر آن است و بیان می‌کند که این مدل پیش‌بینی‌های دقیق‌تر و کم‌ریسک‌تری نسبت به روش‌های پیشین ارائه می‌دهد، و می‌تواند به عنوان ابزاری کارآمد در تحقیقات آتی مورد استفاده قرار گیرد. با توجه به یافته‌ها، فرضیه پژوهش مبنی بر عملکرد بهتر و برتری مدل یادگیری عمیق کوانتومی (QDL) نسبت به مدل‌های کلاسیک سری‌های زمانی، الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق سنتی تایید می‌شود. به بیان دیگر، مدل یادگیری عمیق کوانتومی از نظر دقت پیش‌بینی نسبت به سایر مدل‌های رقیب مطرح شده در پژوهش

حاضر عملکرد دقیق‌تری دارد. نمودار ۲ بازدهی واقعی و پیش‌بینی شده بازار سهام تهران بر اساس مدل یادگیری عمیق کوانتومی را نشان می‌دهد. محور افقی نشان‌دهنده بازه‌های زمانی مربوط به داده‌های آزمون و محور عمودی نشان‌دهنده میزان بازده بازار سهام است.



نمودار ۲: بازدهی واقعی و پیش‌بینی شده بازار سهام

همان‌گونه که مشاهده می‌شود مدل QDL در بیشتر نقاط توانسته است به خوبی رفتار بازار سهام را با دقت بالا پیش‌بینی کند و هم‌پوشانی قابل توجهی با داده‌های واقعی داشته باشد. این نتایج بیانگر آن است که QDL علاوه بر دقت بالا در شرایط عادی بازار، در مواجهه با نوسانات شدید نیز عملکرد پایداری دارد.

بحث و نتیجه‌گیری

یافته‌های پژوهش حاکی از آن است که مدل یادگیری عمیق کوانتومی در پیش‌بینی بازدهی بازار سهام، در مقایسه با مدل‌های کلاسیک سری‌های زمانی مانند ARIMA، الگوریتم‌های یادگیری ماشین مانند SVR و RF و مدل‌های یادگیری عمیق کلاسیک مانند MLP، GRU و LSTM، کم‌ترین خطای پیش‌بینی را به خود اختصاص می‌دهد. همسو با این نتایج، بررسی آماره‌های توصیفی متغیر بازدهی واقعی و سری زمانی پیش‌بینی شده بازدهی بر پایه مدل یادگیری عمیق کوانتومی نشان‌دهنده همخوانی قابل توجه میان ویژگی‌های توزیعی این دو سری است که

بیانگر توانایی مدل پیشنهادی در بازتولید پویایی‌ها و رفتار داده‌های واقعی بازار سهام می‌باشد. همچنین، به‌منظور اطمینان از اعتبار آماری این برتری، از آزمون‌های دایوولد ماریانو و ویلکاکسون استفاده شد که نتایج هر دو آزمون، وجود تفاوت معنادار در دقت پیش‌بینی مدل یادگیری عمیق کوانتومی را نسبت به مدل‌های رقیب تأیید می‌کند. علاوه بر این، مقایسه یافته‌های پژوهش در پیش‌بینی بازدهی بازار سهام کشور با مطالعات راعی و چاوشی (۱۳۸۲)، ذوالفقاری و همکاران (۱۳۹۸)، سهرابی و همکاران (۱۴۰۲)، خلفی و همکاران (۱۴۰۲)، صحرایی و همکاران (۱۴۰۴) و مرادی و همکاران (۱۴۰۴) بر عملکرد برتر مدل QDL در کاهش ریشه میانگین مربعات خطای پیش‌بینی دلالت دارد. در مجموع، فرضیه پژوهش مبنی بر عملکرد بهتر و برتری معنادار مدل یادگیری عمیق کوانتومی نسبت به مدل‌های کلاسیک سری‌های زمانی، الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق سنتی مورد تأیید قرار می‌گیرد. درواقع، مدل یادگیری عمیق کوانتومی نسبت به الگوریتم‌های یادگیری ماشین و یادگیری عمیق کوانتومی مزایای قابل توجهی دارد. نخست، داده‌های کلاسیک در QDL به فضای هیلبرت با ابعاد بالا منتقل می‌شوند که شناسایی دقیق‌تر روابط پنهان بین داده‌ها را فراهم می‌کند. دوم، لایه‌های واریاسیونی و گیت‌های کوانتومی قابلیت نگاشت غیرخطی اطلاعات را فراهم می‌کنند. سوم، از نظر قابلیت مقیاس‌پذیری و توسعه توانمندتر است و با افزایش تعداد کیوبیت‌ها و لایه‌های واریاسیونی می‌تواند دقت پیش‌بینی بالاتری نسبت به سایر مدل‌ها ارائه دهد (محمود و همکاران، ۲۰۲۴). علاوه بر این، مدل یادگیری عمیق کوانتومی با بکارگیری ویژگی درهم تنیدگی کوانتومی توانایی حفظ الگوهای پیچیده سری زمانی را فراهم می‌کند. در واقع وجود ویژگی‌های منحصر به فرد محاسبات کوانتومی مانند درهم‌نهی و درهم‌تنیدگی، مدل یادگیری عمیق کوانتومی را قادر می‌سازد تا الگوهای پنهان و غیرخطی بازار سهام را بهتر شناسایی کرده و در مواجهه با نوسانات شدید و رفتارهای غیرقابل پیش‌بینی بازار عملکرد بهتری داشته باشد (مائو، شرستمالی و کوندو^۱، ۲۰۲۳). این امر به‌ویژه در بازار سهام ایران که با شوک‌های اقتصادی، نوسانات سیاستی و تغییرات رفتاری سرمایه‌گذاران مواجه است، اهمیت دوچندان پیدا می‌کند. یافته‌های پژوهش با نتایج مطالعه کیا و همکاران (۲۰۲۴) و چودری و همکاران (۲۰۲۵) همخوانی دارد که نشان می‌دهند ترکیب شبکه‌های کوانتومی با مدل‌های یادگیری عمیق کلاسیک دقت پیش‌بینی روندهای بازار سهام را نسبت به الگوهای رقیب افزایش می‌دهند.

1. Mao, Shresthamali & Kondo

نتایج پژوهش حاضر پیامدهای سیاستی مهمی برای بازار سرمایه ایران ارایه می‌کند. نخست؛ استفاده از مدل QDL می‌تواند ابزار مؤثری برای کاهش عدم قطعیت و خطای پیش‌بینی در تصمیمات سرمایه‌گذاری باشد. به همین علت، بکارگیری مدل QDL به‌عنوان یک ابزار کارآمد برای بهبود استراتژی‌های سرمایه‌گذاری، کاهش ریسک تصمیم‌گیری و ارتقای کارایی تحلیل‌های مالی، ابزاری فراهم آورد که ریسک زیان ناشی از تصمیمات هیجانی یا اطلاعات ناقص برای سرمایه‌گذاران خرد را کاهش دهد. همچنین، رویکرد QDL سرمایه‌گذاران نهادی و مدیران پرتفوی را قادر می‌سازد تا با شناخت از روند آتی بازار سهام، با بهینه‌سازی ترکیب دارایی‌ها، مدیریت بهتر ریسک سیستماتیک و ارتقای بازدهی پرتفوی، استراتژی‌های بهینه‌تری اتخاذ کنند. بنابراین، در سطح کلان، استفاده از مدل‌های نوین پیش‌بینی مانند QDL می‌تواند به افزایش شفافیت و اعتماد عمومی نسبت به بازار سرمایه منجر شود؛ عاملی که برای گسترش بازارهای مالی و جذب سرمایه‌های خرد و کلان حیاتی است.

دوم، از دید سیاست‌گذاری و نظارتی، نتایج این پژوهش نشان داد بهره‌گیری از فناوری‌های پیشرفته مانند یادگیری عمیق کوانتومی می‌تواند به ارتقای کارایی بازار سرمایه ایران و هم‌سویی آن با روندهای جهانی کمک کند. این امر به‌ویژه در شرایطی اهمیت دارد که بازار سرمایه در اقتصاد ایران نقشی روزافزون در تجهیز منابع مالی و هدایت سرمایه‌ها به بخش‌های مولد بر عهده دارد. بنابراین، تحلیل‌های ناشی از QDL برای مهمترین نهادهای سیاست‌گذار و تنظیم‌گر بازار سرمایه ایران حاوی پیامدهای مهمی است؛ چرا که به کارگیری این دسته از الگوریتم‌ها در سیستم‌های هوشمند معاملاتی و پلتفرم‌های تحلیل مالی، شفافیت و پایداری بیشتری را در بازار ایجاد می‌کند. به عنوان نمونه، سازمان بورس و اوراق بهادار می‌تواند از الگو باز QDL برای پایش هوشمندانه بازار و شناسایی الگوهای معاملاتی غیرعادی یا تشکیل حباب‌های دارایی استفاده کند. این امر به نهاد ناظر امکان می‌دهد تا به جای واکنش انفعالی، سیاست‌های پیش‌گیرانه را در زمان مناسب اعمال نماید.

سوم، یافته‌های پژوهش بیانگر آن است که الگوریتم‌های کوانتومی و به‌ویژه QDL می‌توانند به‌عنوان نسل آینده ابزارهای تحلیلی در بازارهای مالی ایران مطرح شوند. پذیرش فناوری‌های نوین نیازمند توسعه زیرساخت‌های محاسباتی، سرمایه‌گذاری در پژوهش‌های میان‌رشته‌ای و همکاری میان دانشگاه‌ها، سیاست‌گذاران مانند سازمان بورس و اوراق بهادار، نهادهای مالی مانند صندوق‌های سرمایه‌گذاری و بانک‌های کشور است.

با این حال، به کارگیری مدل‌های یادگیری عمیق کوانتومی با محدودیت‌هایی مانند وابستگی شدید این مدل‌ها به داده‌های پرتواتر و با کیفیت مناسب برای آموزش همراه است. در صورت کمبود داده یا وجود نویز و مشکلات ساختاری، دقت پیش‌بینی کاهش یافته و احتمال بیش‌برازش در مدل افزایش می‌یابد.

ملاحظات اخلاقی

مشارکت نویسندگان

کلیه نویسندگان به‌طور یکسان در طراحی، اجرا و نگارش تمامی بخش‌های این پژوهش مشارکت داشته‌اند.

حامی مالی

این پژوهش از هیچ‌گونه حمایت مالی برخوردار نمی‌باشد.

تعارض منافع

نویسندگان اعلام می‌کنند که هیچ‌گونه تعارض منافع مرتبط با محتوای این مقاله وجود ندارد.

سپاسگزاری

نویسندگان از داوران ناشناس به‌سبب ارائه دیدگاه‌ها و نظرات سازنده که نقش مهمی در بهبود این پژوهش داشته است، قدردانی می‌کنند.

References

- Aishwarya, C. Venkatesan, M. & Prabhavathy, P. (2025). A scoping survey of quantum machine learning and deep learning for real-world applications. *Procedia Computer Science*, 258, 633-646. <https://doi.org/10.1016/j.procs.2025.04.297>.
- Boonpan, S. & Sarakorn, W. (2025). Deep neural network model enhanced with data preparation for the directional predictability of multi-stock returns. *Journal of Open Innovation Technology, Market, and Complexity*, 11(1), 1-15. <https://doi.org/10.1016/j.joitmc.2024.100438>.
- Chen, J. Ma, F. Qiu, X. & Li, T. (2023). The role of categorical EPU indices in predicting stock-market returns. *International Review of Economics and Finance*, 87, 365-378. <https://doi.org/10.1016/j.iref.2023.05.003>.
- Chehimi, M. Chen, S. Y. C. Saad, W. & Yoo, S. (2024). Federated quantum long short-term memory (fedqlstm). *Quantum Machine Intelligence*, 6(2), 1-20. <https://doi.org/10.48550/arXiv.2312.14309>.
- Choudhary, P. K. Innan, N. Shafique, M. & Singh, R. (2025). HQNN-FSP: A hybrid classical-quantum neural network for regression-based financial stock market prediction. *arXiv preprint arXiv:2503.15403*. <https://doi.org/10.48550/arXiv.2503.15403>.
- Coroneo, Laura. & Iacone, F. (2025). Testing for equal predictive accuracy with strong dependence. *International Journal of Forecasting*, 41(3), 1073-1092. <https://doi.org/10.1016/j.ijforecast.2024.11.003>.
- Dai, Z. Zhu, H. Chang, X. & Wen, F. (2025). Forecasting stock returns: The role of vix-based upper and lower shadow of Japanese candlestick. *Financial Innovation*, 11(1), 1-19. <https://doi.org/10.1186/s40854-024-00682-8>.
- Detthamrong, U. Klangbunrueang, R. Chansanam, W. & Dasri, R. (2025). Deep learning for sustainable finance: robust ESG index forecasting in an emerging market context. *Sustainability*, 18(1), 110. <https://doi.org/10.3390/su18010110>.
- Fotros, M. H. & Maaboudi, R. (2021). Comovement between oil price and Iranian stock market returns: wavelet analysis method. *Journal of Applied Economics Studies in Iran*, 10(38), 55-68. <https://doi.org/10.22084/AES.2021.24350.3303>.
- Gupta, S. Nachappa, S. & Paramanandham, N. (2025). Stock market time series forecasting using comparative machine learning algorithms. *Procedia Computer Science*, 252, 893-904. <https://doi.org/10.1016/j.procs.2025.01.050>.
- Ibrahim, M. & Musah, A. (2014). An econometric analysis of the impact of macroeconomic fundamentals on stock market returns in Ghana. *Research in Applied Economics*, 6(2), 47-72. <https://doi.org/10.5296/rae.v6i2.5146>.
- Issahaku, H. Ustarz, Y. & Domanban, P. B. (2013). Macroeconomic variables and stock market returns in Ghana: any causal link. *Asian Economic and Financial Review*, 3(8):1044-1062.

<https://ideas.repec.org/a/asi/aeafvj/v3y2013i8p1044-1062id1070.html>.

Henrique, B. M. Sobreiro, V. A. & Kimura, H. (2018). Stock price prediction using support vector regression on daily and up to the minute prices. *Journal of finance and data science*, 4(3), 183-201.

<https://doi.org/10.1016/j.jfds.2018.04.003>.

Javaid, H. A. (2024). Ai-driven predictive analytics in finance: Transforming risk assessment and decision-making. *Advances in Computer Sciences*, 7(1), 1-9. <https://www.scirp.org/reference/referencespapers?referenceid=4031410>.

Kea, K., Kim, D., Huot, C., Kim, T. K., & Han, Y. (2024). A hybrid quantum-classical model for stock price prediction using quantum-enhanced long short-term memory. *Entropy*, 26(11), 954. <https://doi.org/10.3390/e26110954>.

Khaidem, L. Saha, S. & Dey, S. R. (2016). Predicting the direction of stock market prices using random forest. *arXiv preprint arXiv*, 1605.00003.

<https://doi.org/10.48550/arXiv.1605.00003>.

Khalafi, S. Masjed Mousavi, M. S. & Omid, A. (2023). A comparison of artificial neural networks in forecasting stock returns. *Novel Research Approaches in Management and Accounting*, 7(89), 720-753. <http://noo.rs/c1AE7> (in Persian).

Krichen, M., & Mihoub, A. (2025). Long short-term memory networks: A comprehensive survey. *AI*, 6(9), 215. <https://doi.org/10.3390/ai6090215>.

Mahmood, T. Ahmad, I. Ansar, M. M. Z. Darwish, J. A. & Sherwani, R. A. K. (2024). Comparative study of long short-term memory (LSTM) and quantum long short-term memory (QLSTM): prediction of stock market movement. *arXiv preprint arXiv*:2409.08297, <https://doi.org/10.48550/arXiv.2409.08297>.

Mao, Y. Shresthamali, S. & Kondo, M. (2023). Quantum circuit fidelity improvement with long short-term memory networks. *arXiv preprint arXiv*:2303.17523, <https://doi.org/10.1002/qute.202500022>.

Mehravian, S. S., & Davari-Ardakani, H. (2025). An integrated model of sentiment analysis and quantitative index data for predicting stock market trends: A case study of Tehran stock exchange. *Expert Systems with Applications*, 269, 126298. <https://doi.org/10.1016/j.eswa.2024.126298>.

Mienye, I. D. Swart, T. G. & Obaido, G. (2024). Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *Information*, 15(9), 1-34. <https://doi.org/10.3390/info15090517>.

Muhammad, D. Ahmed, I. Naveed, K. & Bendeche, M. (2024). An explainable deep learning approach for stock market trend prediction. *Heliyon*, 10(21), 1-15. <https://doi.org/10.1016/j.heliyon.2024.e40095>.

Moradi, M. Neshat, N. & Sardari Zarchi, M. (2025). Representing investment knowledge based on returns in the Iranian stock market using deep neural network models under environmental uncertainty. *Financial Research Journal*, 27(3), 531-565. <https://doi.org/10.22059/FRJ.2024.370564.1007554> (in Persian).

- Najem, R. Bahnasse, A. & Talea, M. (2024). Toward an enhanced stock market forecasting with machine learning and deep learning models. *Procedia. Computer Science*, 241, 97-103. <https://doi.org/10.1016/j.procs.2024.08.015>.
- Namaki, A. & Kazemi Bavill, A. (2025). The relationship between the overall stock market index, treasury bond returns, and liquidity resilience. *Quarterly Journal of Securities Exchange*, 18(69), 1–24. <https://doi.org/10.22034/jse.2024.12353.2215> (in Persian).
- Pagliaro, A. (2025). Artificial intelligence vs. efficient markets: A critical reassessment of predictive models in the big data era. *Electronics*, 14(9), 1-48. <https://doi.org/10.3390/electronics14091721>.
- Paquet, E. & Soleymani, F. (2022). Quantumleap: hybrid quantum neural network for financial predictions. *Expert Systems With Applications*, 195, 116583. <https://doi.org/10.1016/j.eswa.2022.116583>.
- Perekhodko, A., & Ślepaczuk, R. (2025). Stochastic Volatility Modelling with LSTM Networks: A Hybrid Approach for S&P 500 Index Volatility Forecasting. *arXiv preprint arXiv:2512.12250*. <https://doi.org/10.48550/arXiv.2512.12250>.
- Pohl, W. Schmedders, K. & Wilms, O. (2018). Higher order effects in asset pricing models with long-run risks. *Journal of Finance*, 73(3), 1061-1111 <https://ssrn.com/abstract=2540586>.
- Raei, R. & Chavoshi, K. (2003). Forecasting stock returns in the Tehran stock exchange: An artificial neural network model and a multifactor model. *Financial Research*, 5(15), 97–120. https://jfr.ut.ac.ir/article_11352.html (in Persian).
- Ren, T. & Li, S. (2025). Stock market forecasting based on machine learning: The role of investor sentiment. *Physica A: Statistical Mechanics and its Applications*, 666, 130533. <https://doi.org/10.1016/j.physa.2025.130533>.
- Rezaei, A. Abdellatif, I. & Umar, A. (2025). Towards economic sustainability: A comprehensive review of artificial intelligence and machine learning techniques in improving the accuracy of stock market movements. *International Journal of Financial Studies*, 13(1), 1-28. <https://doi.org/10.3390/ijfs13010028>.
- Sarraf, F. Nasiri, Z. Tanhaei, M. R. Emamvardi, G. & Najafi M. A. (2024). Stock return prediction based on bayesian averaging models: continuous wavelet and financial quantum analysis approach. *Financial Management Strategy*, 13(1). 167–192. <https://doi.org/10.22051/JFM.2024.43067.2794> (in Persian).
- Sahraei, R. Gholizadeh, A. A. Sepehr doost, H. & Hosseini doost, S. E. (2025). Portfolio optimization based on prediction in the Tehran stock exchange: NARX and LSTM neural network approaches. *Quarterly Journal of Securities*

- Exchange*, 18(70)105- 134. <https://doi.org/10.22034/jse.2024.12328.2202> (in Persian).
- Sood, S. & Bhushan, D. P. (2025). Forecasting daily stock market trends: A random forest approach for predicting next-day return direction. *National Journal of Commerce and Management*, 11(2), 47-51. <https://njcm.pratibhaspandan.org/wp-content/uploads/v11i02a07.pdf>.
- Sohrabi, M. Mirbarg Kar, S. M. Chirani, E. & Kheradiar, S. (2023). Comparison of various machine learning models in predicting the stock market index. *Financial Engineering and Securities Management*, 56(14), 19–36. (in Persian). https://journals.iau.ir/article_697295_5158567561144ec9646114cf0c12eff1.pdf
- Srivastava, M. Rao, A. Parihar, J. S. Chavriya, S. & Singh, S. (2023). What do the AI methods tell us about predicting price volatility of key natural resources: Evidence from hyperparameter tuning. *Resources Policy*, 80, 103249. <https://doi.org/10.1016/j.resourpol.2022.103249>.
- Wu, H. Wang, Q. Li, J. & Deng, Z. (2025). Enhancing stock return prediction in the Chinese market: A GAN-based approach. *Research in International Business and Finance*, 75, 102760. <https://doi.org/10.1016/j.ribaf.2025.102760>
- Zhai, D. Zhang, T. Liang, G. & Liu, B. (2025). Research on crude oil futures price prediction methods: A perspective based on quantum deep learning. *Energy*, 320, 1-26. <https://doi.org/10.1016/j.energy.2025.135080>.
- Zhou, S. Zhang, Z. Zhang, R. Yin, Y. Chang, C. H. & Shen, Q. (2025). Regression and forecasting of us stock returns based on LSTM. *arXiv preprint arXiv:2502.05210*. <https://doi.org/10.48550/arXiv.2502.05210>.
- Zolfaghari, M. Sahabi, B. & Bakhtiarian, M. J. (2019). Designing a model for predicting the overall stock market index returns (with an emphasis on hybrid learning network models and the GARCH family models). *Financial Engineering and Securities Management*, 11(42), 138–171. <https://sanad.iau.ir/Journal/fej/Article/1078174> (in Persian).