




Journal Website

Article history:  
Received 21 January 2026  
Revised 02 June 2026  
Accepted 09 June 2026  
Initial Publication 10 June 2026  
Final Publication 22 June 2027

## Dynamic Management and Business Analysis

Volume 6, Issue 2, pp 1-19



E-ISSN: 3041-8933

# Investigating the Determinants of Stock Prices and Comparing the Performance of Advanced Nonlinear Methods in Forecasting

Parasto. Azami<sup>1</sup>, Najmeh. Kargar Kamvar<sup>2\*</sup>, Hoda. Hemmati<sup>2</sup>

<sup>1</sup> PhD Student, Department of Financial Engineering, Ro.C., Islamic Azad University, Roudehen, Iran

<sup>2</sup> Department of Accounting, Ro.C., Islamic Azad University, Roudehen, Iran

\* Corresponding author email address: Kargarkamvar@iau.ac.ir

### Article Info

#### Article type:

Original Research

#### How to cite this article:

Azami, P., Kargar Kamvar, N., & Hemmati, H. (2027). Investigating the Determinants of Stock Prices and Comparing the Performance of Advanced Nonlinear Methods in Forecasting. *Dynamic Management and Business Analysis*, 6(2), 1-19. <https://doi.org/10.61838/dmbaj.374>



© 2027 the author(s). Published by Knowledge Management Scientific Association. This is an open access article under the terms of the Creative Commons Attribution 4.0 International (CC BY 4.0) License.

### ABSTRACT

**Objective:** The objective of this study was to compare the predictive accuracy and performance of fuzzy regression, genetic algorithm, support vector machine, decision tree, and machine learning methods in forecasting stock closing prices using real out-of-sample observations.

**Methodology:** This applied quantitative study utilized daily stock market data of Isfahan Steel Company from January 1, 2024, to November 19, 2025. After removing highly collinear variables, selected predictors were incorporated into the forecasting models. The final 30 observations were reserved as real out-of-sample data to evaluate forecasting performance. Fuzzy regression, genetic algorithm, interpretable machine learning, decision tree, and support vector machine models were developed and compared. Prediction accuracy was assessed using Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Error (MAE).

**Findings:** The results demonstrated significant differences in predictive performance among the examined models. Fuzzy regression achieved the highest forecasting accuracy, producing the lowest error values (MSE = 26, RMSE = 31, MAE = 996). Interpretable machine learning ranked second (MSE = 32, RMSE = 40, MAE = 1,567). Decision tree models showed moderate performance (MSE = 53, RMSE = 71, MAE = 5,027). In contrast, support vector machines and genetic algorithms generated substantially larger forecasting errors and exhibited weaker generalization ability on out-of-sample data. Furthermore, opening price, highest price, and lowest price emerged as the most influential predictors across most forecasting models.

**Conclusion:** The findings indicate that interpretable forecasting approaches, particularly fuzzy regression, provide a superior balance between predictive accuracy and economic interpretability. These models not only deliver reliable forecasts but also facilitate a clearer understanding of the relationships among financial variables. Consequently, they can serve as effective tools for short-term stock price forecasting and evidence-based investment decision-making in capital markets.

**Keywords:** Stock Price Forecasting; Fuzzy Regression; Machine Learning; Genetic Algorithm; Support Vector Machine; Decision Tree.



## EXTENDED ABSTRACT

### Introduction

Forecasting stock prices remains one of the most challenging and significant issues in financial economics and capital market analysis. Accurate stock price prediction is essential for investors, portfolio managers, financial institutions, and policymakers because it directly influences investment decisions, risk management strategies, and capital allocation efficiency. However, stock markets are characterized by uncertainty, volatility, and complex interactions among economic, financial, behavioral, and institutional variables, making accurate prediction extremely difficult. Traditional linear forecasting models often fail to capture the nonlinear and dynamic nature of financial markets, leading researchers to explore more sophisticated computational and machine-learning approaches (Al Janabi, 2021; Dhifaoui, 2022).

Recent developments in artificial intelligence, machine learning, and computational finance have transformed the landscape of financial forecasting. Advanced algorithms can process large volumes of historical and real-time data, identify hidden patterns, and model nonlinear relationships more effectively than conventional statistical techniques. Studies have demonstrated the potential of machine learning methods, support vector machines, neural networks, and hybrid optimization algorithms in improving forecasting performance and investment outcomes (Hu et al., 2021; Masini et al., 2023; Thakkar & Chaudhari, 2021). Furthermore, modern forecasting frameworks increasingly integrate multiple information sources, including market indicators, valuation ratios, macroeconomic variables, sentiment indicators, and behavioral factors, to enhance predictive accuracy (Mansilla-Lopez, 2025; Tomar & Periyasamy, 2023).

The growing popularity of machine learning techniques in financial forecasting is supported by numerous empirical studies. Sheth and Shah emphasized the superior capability of machine learning algorithms in identifying future stock price trends compared with many traditional approaches (Sheth & Shah, 2023). Similarly, Yang proposed multimodal forecasting architectures based on multi-task learning and attention mechanisms, demonstrating substantial improvements in stock price prediction accuracy (Yang, 2024). Advances in time-series forecasting have also highlighted the importance of sophisticated nonlinear methods for modeling financial data characterized by structural breaks and volatility clustering (Masini et al., 2023).

At the same time, financial researchers have emphasized the importance of understanding the determinants of stock returns and price movements. Valuation ratios, cyclical market factors, investor expectations, macroeconomic announcements, and managerial forecasts have all been shown to influence stock performance significantly. Research conducted in various international markets indicates that valuation measures and cyclical components can improve stock return predictability (Yu et al., 2023). Studies have further demonstrated that managerial earnings forecasts contain valuable information regarding future stock returns (Kitagawa & Shuto, 2024). Additionally, patent-related innovation indicators and firm-level technological capabilities have been associated with stock market performance in emerging economies (Tsai et al., 2024).

Behavioral finance perspectives also contribute to understanding stock market dynamics. Investor sentiment, cognitive biases, herding behavior, and anchoring effects can significantly influence asset prices and create deviations from fundamental values. Empirical evidence suggests that irrational investor behavior and psychological biases contribute to market fluctuations and return predictability (Birz et al.,

2022; Ye et al., 2020). Moreover, recent studies have shown that social media sentiment and digital information flows can improve volatility forecasting and market prediction models (Saravanos & Kanavos, 2025).

Several forecasting methods have emerged as particularly promising. Support Vector Machines (SVMs) have demonstrated strong predictive capabilities in high-dimensional financial datasets (Tellez Gaytan et al., 2022). Hybrid neural network architectures optimized through swarm intelligence algorithms have also achieved remarkable forecasting performance (Kumar et al., 2022). Furthermore, ensemble forecasting and forecast combination approaches have been shown to outperform individual models in many financial applications (Lv & Qi, 2022). Reinforcement learning frameworks have recently expanded the possibilities of dynamic portfolio management and adaptive forecasting systems (Kuna, 2022).

Within the Iranian context, several studies have examined stock return forecasting and capital market dynamics. Research on variable reduction techniques demonstrated that appropriate feature selection significantly improves forecasting performance (Setayesh & Kazemnejad, 2019). Studies based on network analysis have highlighted the importance of structural relationships among firms in the capital market (Taghizadeh & Abdzadeh Konafi, 2023). Investigations of hybrid forecasting models have also reported favorable outcomes from combining machine learning and optimization algorithms (Ebadati et al., 2021; Fadaei et al., 2021). Furthermore, research on capital productivity and risk-based stock return forecasting has emphasized the role of financial fundamentals in explaining market behavior (Akhbari et al., 2024; Alimohammadpour et al., 2020). More recently, advanced neural network architectures have been successfully applied to forecasting the Tehran Stock Exchange index, demonstrating the growing relevance of nonlinear forecasting techniques in Iranian financial markets (Taslimpour et al., 2026).

Despite substantial progress, no consensus exists regarding the most effective forecasting methodology. Different studies report conflicting findings depending on market conditions, data characteristics, and model specifications. Therefore, a comprehensive comparison of multiple nonlinear forecasting approaches using real out-of-sample observations remains necessary. The present study addresses this gap by comparing fuzzy regression, genetic algorithms, support vector machines, decision trees, and machine learning methods in forecasting stock closing prices using actual market data.

### **Methods and Materials**

This applied quantitative study utilized daily trading data from Isfahan Steel Company over the period from January 1, 2024, to November 19, 2025. The dataset included daily observations of various market indicators and stock-related variables. Variables exhibiting severe multicollinearity were removed during the preprocessing stage to improve model stability and estimation accuracy.

The final set of explanatory variables included stock closing prices, transaction counts, percentages of net individual trading activity, average individual purchase values, and average individual selling values. Five nonlinear forecasting methods were employed: Fuzzy Regression, Genetic Algorithm, Interpretable Machine Learning, Decision Tree, and Support Vector Machine.

To evaluate forecasting performance objectively, the final 30 trading-day observations were excluded from model estimation and reserved as out-of-sample validation data. Model performance was assessed using Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Error (MAE). These measures provided a comprehensive assessment of predictive accuracy and generalization capability across forecasting methods.



The significance and relative importance of explanatory variables were examined within each model. Comparative analyses were then conducted to identify the forecasting approach that provided the most accurate and stable predictions under real market conditions.

### **Findings**

The results revealed substantial differences in forecasting performance among the examined nonlinear methods. Fuzzy Regression achieved the highest level of forecasting accuracy and demonstrated the strongest out-of-sample predictive performance. This model produced the lowest forecasting errors, with an MSE of 26, RMSE of 31, and MAE of 996, indicating superior stability and reliability.

Interpretable Machine Learning ranked second among the forecasting methods. The model achieved an MSE of 32, RMSE of 40, and MAE of 1,567. Although its forecasting errors were slightly larger than those of Fuzzy Regression, the model demonstrated strong predictive capability and robust generalization performance.

The Decision Tree model exhibited moderate forecasting performance. It achieved an MSE of 53, RMSE of 71, and MAE of 5,027. While capable of capturing important nonlinear relationships, its predictive accuracy was substantially lower than that of Fuzzy Regression and Interpretable Machine Learning.

Support Vector Machine showed weaker out-of-sample performance despite displaying strong in-sample fitting characteristics. Forecasting errors increased considerably when applied to real observations, indicating limited generalization capability relative to the best-performing models.

The Genetic Algorithm produced the weakest forecasting performance among all examined methods. Forecasting errors were substantially larger than those of the other approaches, suggesting limited effectiveness when applied independently to stock price prediction.

Analysis of variable importance revealed that Highest Price, Lowest Price, Opening Price, and Last Transaction Price consistently emerged as the most influential predictors across multiple models. These variables accounted for a significant proportion of the predictive power and appeared repeatedly among the top-ranking explanatory factors. In contrast, several transaction-related variables demonstrated limited predictive significance and contributed minimally to forecasting performance.

Overall, the empirical results demonstrated that simpler and more interpretable nonlinear methods outperformed several more sophisticated machine learning approaches when evaluated using real out-of-sample observations.

### **Discussion and Conclusion**

The findings of this study demonstrate that forecasting performance depends not only on model complexity but also on the ability of a method to generalize effectively to unseen data. The superior performance of Fuzzy Regression suggests that financial markets contain substantial uncertainty and ambiguity that can be modeled effectively through flexible, uncertainty-aware frameworks. By accommodating imprecise relationships among variables, Fuzzy Regression appears particularly well suited to the dynamic and uncertain nature of stock market behavior.

The strong performance of Interpretable Machine Learning further highlights the value of balancing predictive accuracy with transparency. While many sophisticated machine learning models operate as black-box systems, interpretable approaches provide valuable insights into the underlying drivers of stock price movements. Such transparency is especially important for financial analysts and

investment professionals who require both accurate forecasts and meaningful explanations of market behavior.

The comparatively weaker performance of Support Vector Machines and Genetic Algorithms suggests that increased algorithmic sophistication does not automatically guarantee improved forecasting outcomes. These methods may be more vulnerable to overfitting, parameter sensitivity, and changing market conditions. Consequently, models that achieve excellent in-sample performance may fail to maintain accuracy when applied to new observations.

The identification of Highest Price, Lowest Price, Opening Price, and Last Transaction Price as dominant predictors confirms the central role of market price dynamics in forecasting future stock values. These variables capture essential information regarding short-term market expectations, trading behavior, and investor sentiment, making them valuable indicators for predictive modeling.


From a practical perspective, the findings provide important guidance for investors, portfolio managers, and financial institutions. The results indicate that interpretable forecasting methods can deliver highly competitive predictive performance while maintaining transparency and usability. Such models may therefore offer a more effective foundation for investment decision-making than highly complex black-box algorithms.

In conclusion, this study demonstrates that Fuzzy Regression provides the most accurate and stable forecasts of stock closing prices among the examined nonlinear methods. Interpretable Machine Learning also exhibits strong predictive capability, while Decision Trees achieve moderate success. Support Vector Machines and Genetic Algorithms show comparatively weaker out-of-sample performance. These findings emphasize the importance of model interpretability, robustness, and generalization ability in financial forecasting and suggest that future forecasting frameworks should prioritize both predictive accuracy and practical applicability when analyzing stock market behavior.



## مدیریت پویا و تحلیل کسب و کار

دوره ۶، شماره ۲، صفحه ۱۹-۱



# بررسی عوامل مؤثر بر قیمت سهام و مقایسه کارایی آنها در پیش‌بینی با روش‌های پیشرفته غیرخطی

پرستو اعظمی<sup>۱</sup>، نجمه کارگر کامور<sup>۲\*</sup>، هدی همتی<sup>۲</sup>

۱. دانشجوی دکتری، گروه مهندسی مالی، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران

۲. گروه حسابداری، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران

\* ایمیل نویسنده مسئول: Kargarkamvar@iau.ac.ir

### اطلاعات مقاله

### چکیده

#### نوع مقاله

پژوهشی اصیل

#### نحوه استناد به این مقاله:

اعظمی، پرستو، کارگر کامور، نجمه، و همتی، هدی. (۱۴۰۵). بررسی عوامل مؤثر بر قیمت سهام و مقایسه کارایی آنها در پیش‌بینی با روش‌های پیشرفته غیرخطی. مدیریت پویا و تحلیل کسب و کار، ۶(۲)، ۱۹-۱.



© ۱۴۰۵ تمامی حقوق انتشار این مقاله متعلق به نویسنده(گان) است. انتشار این مقاله به صورت دسترسی آزاد مطابق با گواهی (CC BY 4.0) صورت گرفته است.

**هدف:** هدف این پژوهش مقایسه دقت و کارایی روش‌های رگرسیون فازی، الگوریتم ژنتیک، ماشین بردار پشتیبان، درخت تصمیم و یادگیری ماشین در پیش‌بینی قیمت پایانی سهام با استفاده از داده‌های واقعی خارج از نمونه بود. **روش‌شناسی:** این پژوهش از نوع کاربردی و با رویکرد کمی انجام شد. داده‌های مورد استفاده شامل اطلاعات روزانه سهام شرکت فولاد اصفهان در بازه زمانی ۱ ژانویه ۲۰۲۴ تا ۱۹ نوامبر ۲۰۲۵ بود. پس از حذف متغیرهای دارای هم‌خطی شدید، متغیرهای منتخب برای مدل‌سازی مورد استفاده قرار گرفتند. برای ارزیابی توان پیش‌بینی مدل‌ها، ۳۰ مشاهده پایانی به‌عنوان داده‌های واقعی خارج از نمونه در نظر گرفته شد. مدل‌های رگرسیون فازی، الگوریتم ژنتیک، یادگیری ماشین تفسیرپذیر، درخت تصمیم و ماشین بردار پشتیبان بر داده‌ها برازش شدند و عملکرد آن‌ها با استفاده از شاخص‌های میانگین توان دوم خطا (MSE)، جذر میانگین توان دوم خطا (RMSE) و میانگین قدر مطلق خطا (MAE) مقایسه شد. **یافته‌ها:** نتایج نشان داد که بین مدل‌های مورد بررسی تفاوت معناداری در دقت پیش‌بینی وجود دارد. رگرسیون فازی با کمترین میزان خطا (MSE=۲۶، RMSE=۳۱، MAE=۹۹۶) بهترین عملکرد را در پیش‌بینی قیمت پایانی سهام ارائه کرد. مدل یادگیری ماشین در رتبه دوم قرار گرفت (MSE=۳۲، RMSE=۴۰، MAE=۱۵۶۷). درخت تصمیم عملکرد متوسطی داشت (MSE=۵۳، RMSE=۷۱، MAE=۵۰۲۷)، در حالی که ماشین بردار پشتیبان و الگوریتم ژنتیک به ترتیب بیشترین میزان خطا را نشان دادند و توان تعمیم‌پذیری ضعیف‌تری در داده‌های خارج از نمونه داشتند. همچنین متغیرهای با بالاترین قیمت، پایین‌ترین قیمت و قیمت بازگشایی در اغلب مدل‌ها از مهم‌ترین عوامل مؤثر بر قیمت سهام بودند. **نتیجه‌گیری:** یافته‌های پژوهش نشان داد که مدل‌های تفسیرپذیر، به‌ویژه رگرسیون فازی، علاوه بر برخورداری از دقت پیش‌بینی بالا، امکان تحلیل اقتصادی و تبیین بهتر روابط میان متغیرها را فراهم می‌کنند. بنابراین، این مدل‌ها می‌توانند به‌عنوان ابزارهای مؤثر برای پیش‌بینی کوتاه‌مدت قیمت سهام و پشتیبانی از تصمیم‌گیری سرمایه‌گذاران در بازار سرمایه مورد استفاده قرار گیرند.

**کلیدواژه‌گان:** پیش‌بینی قیمت سهام، رگرسیون فازی، یادگیری ماشین، الگوریتم ژنتیک، ماشین بردار پشتیبان، درخت

تصمیم.

## مقدمه

بازار سرمایه یکی از مهم‌ترین ارکان نظام مالی هر کشور محسوب می‌شود و نقش تعیین‌کننده‌ای در تجهیز و تخصیص بهینه منابع مالی، هدایت سرمایه‌گذاری‌ها و تسهیل رشد اقتصادی دارد. در این میان، قیمت سهام به‌عنوان مهم‌ترین شاخص ارزش‌گذاری شرکت‌ها و مبنای تصمیم‌گیری سرمایه‌گذاران، همواره مورد توجه پژوهشگران، تحلیلگران مالی و سیاست‌گذاران بوده است. با وجود توسعه نظریه‌های مالی و پیشرفت ابزارهای تحلیل داده، پیش‌بینی قیمت سهام همچنان یکی از پیچیده‌ترین مسائل در حوزه مالی به شمار می‌رود؛ زیرا رفتار بازارهای مالی تحت تأثیر مجموعه‌ای از عوامل اقتصادی، سیاسی، اجتماعی، روان‌شناختی و حتی فناوری قرار دارد که روابط میان آن‌ها اغلب غیرخطی، پویا و همراه با عدم قطعیت است. به همین دلیل، دستیابی به مدل‌هایی که بتوانند رفتار قیمت سهام را با دقت قابل قبول پیش‌بینی کنند، به یکی از مهم‌ترین چالش‌های تحقیقات مالی تبدیل شده است (Al Janabi, 2021; Dhifaoui, 2022; Masini et al., 2023).

در رویکردهای کلاسیک مالی، فرض بر آن بوده است که قیمت سهام عمدتاً تحت تأثیر اطلاعات اقتصادی و مالی قابل اندازه‌گیری قرار دارد و می‌توان از طریق مدل‌های آماری و اقتصادسنجی خطی، روندهای آتی آن را پیش‌بینی کرد. با این حال، تجربه بازارهای مالی در دهه‌های اخیر نشان داده است که رفتار سرمایه‌گذاران، انتظارات ذهنی، سوگیری‌های شناختی و تغییرات ناگهانی محیط اقتصادی می‌توانند موجب انحراف قابل توجه قیمت‌ها از الگوهای خطی شوند. پژوهش‌های حوزه مالی رفتاری نیز تأکید می‌کنند که رفتارهای توده‌وار، زیان‌گریزی و سوگیری‌های شناختی سرمایه‌گذاران نقش مهمی در شکل‌گیری نوسانات بازار دارند و همین امر موجب می‌شود پیش‌بینی قیمت سهام تنها بر اساس متغیرهای سنتی مالی با محدودیت مواجه شود (Birz et al., 2022; Yang, 2023; Ye et al., 2020). افزون بر این، مطالعات اخیر نشان داده‌اند که متغیرهای نوظهوری همچون احساسات بازار، داده‌های شبکه‌های اجتماعی، شاخص‌های ژئوپلیتیکی و اطلاعات فناورانه نیز می‌توانند قدرت پیش‌بینی قابل توجهی برای بازده و قیمت سهام داشته باشند (Alqahtani et al., 2020; Saravanos & Kanavos, 2025; Tsai et al., 2024).

در پاسخ به این پیچیدگی‌ها، استفاده از روش‌های غیرخطی و الگوریتم‌های هوش مصنوعی در سال‌های اخیر رشد چشمگیری یافته است. توسعه فناوری‌های پردازش داده و افزایش توان محاسباتی رایانه‌ها امکان استفاده از مدل‌هایی را فراهم کرده است که قادرند الگوهای پنهان و روابط غیرخطی میان متغیرها را شناسایی کنند. در این میان، یادگیری ماشین به یکی از مهم‌ترین ابزارهای تحلیل بازارهای مالی تبدیل شده است. مطالعات مختلف نشان داده‌اند که الگوریتم‌های یادگیری ماشین می‌توانند در بسیاری از موارد عملکرد بهتری نسبت به مدل‌های سنتی در پیش‌بینی قیمت و بازده سهام ارائه دهند (Hu et al., 2021; Sheth & Shah, 2023; Thakkar & Chaudhari, 2021). همچنین مرورهای علمی گسترده حاکی از آن است که پیشرفت‌های اخیر در یادگیری ماشین و یادگیری عمیق موجب افزایش چشمگیر توان مدل‌ها در تحلیل سری‌های زمانی مالی شده است (Mansilla-Lopez, 2025; Masini et al., 2023).

یکی از مهم‌ترین روش‌های مورد استفاده در این حوزه، ماشین بردار پشتیبان است که به دلیل توانایی بالا در مدل‌سازی روابط پیچیده و غیرخطی مورد توجه پژوهشگران قرار گرفته است. این روش با استفاده از توابع هسته و تبدیل داده‌ها به فضاهای با ابعاد بالاتر، امکان تفکیک بهتر الگوهای موجود در داده‌های مالی را فراهم می‌کند. با وجود مزایای قابل توجه، برخی مطالعات نشان داده‌اند که عملکرد ماشین بردار پشتیبان در شرایط مختلف بازار و بسته به ویژگی داده‌ها می‌تواند متفاوت باشد و همواره برتری مطلق نسبت به سایر روش‌ها ندارد (Akyildirim et al., 2022; Ebadati et al., 2021; Tellez Gaytan et al., 2022). از سوی دیگر، الگوریتم‌های فراابتکاری نظیر الگوریتم ژنتیک نیز به دلیل توانایی در جستجوی فضای وسیع پاسخ‌ها و بهینه‌سازی پارامترهای مدل‌ها، به طور گسترده در مطالعات مالی مورد استفاده



قرار گرفته‌اند. پژوهش‌ها نشان داده‌اند که ترکیب الگوریتم ژنتیک با سایر روش‌های یادگیری ماشین می‌تواند دقت پیش‌بینی را افزایش دهد، هرچند نتایج حاصل از این روش‌ها در همه بازارها یکسان نبوده است (Ebadati et al., 2021; Fadaei et al., 2021; Kumar et al., 2022).

در کنار روش‌های مبتنی بر هوش مصنوعی، برخی پژوهشگران بر اهمیت مدل‌های تفسیرپذیر تأکید کرده‌اند. اگرچه بسیاری از مدل‌های پیچیده یادگیری ماشین از دقت بالایی برخوردار هستند، اما ماهیت جعبه‌سیاه آن‌ها موجب می‌شود تحلیلگران مالی نتوانند نقش دقیق متغیرهای مختلف را در فرآیند پیش‌بینی درک کنند. این موضوع به‌ویژه در تصمیم‌گیری‌های سرمایه‌گذاری و مدیریت ریسک اهمیت فراوانی دارد؛ زیرا سرمایه‌گذاران علاوه بر پیش‌بینی عددی قیمت، به درک عوامل اثرگذار بر آن نیز نیاز دارند. از این منظر، روش‌هایی مانند رگرسیون فازی و درخت تصمیم می‌توانند با حفظ قابلیت تفسیر، روابط غیرخطی و عدم قطعیت موجود در داده‌های مالی را مدل‌سازی کنند و اطلاعات ارزشمندی برای تحلیلگران فراهم آورند (Dhifaoui, 2022; Mansilla-Lopez, 2025; Masini et al., 2023).

مطالعات انجام‌شده در سطح بین‌المللی نیز بر اهمیت توسعه روش‌های پیش‌بینی بازار سهام تأکید دارند. برای مثال، پژوهش‌های انجام‌شده در بازارهای مالی چین نشان داده‌اند که نسبت‌های ارزش‌گذاری و شاخص‌های مبتنی بر نوآوری می‌توانند نقش مهمی در پیش‌بینی بازده سهام ایفا کنند (Tsai et al., 2024; Yu et al., 2023). همچنین بررسی بازار سهام ژاپن نشان داده است که پیش‌بینی‌های مدیریتی و اطلاعات منتشرشده توسط شرکت‌ها می‌توانند اطلاعات معناداری درباره بازده آتی سهام در اختیار سرمایه‌گذاران قرار دهند (Kitagawa & Shuto, 2024). از سوی دیگر، پژوهش‌های انجام‌شده بر روی داده‌های چندبازاری نشان داده‌اند که استفاده از روش‌های ترکیبی و مدل‌های ادغامی می‌تواند دقت پیش‌بینی را نسبت به استفاده از یک مدل منفرد افزایش دهد (Lv & Qi, 2022; Thakkar & Chaudhari, 2021). افزون بر این، کاربرد یادگیری تقویتی و مدل‌های چندوظیفه‌ای مبتنی بر مکانیزم توجه نیز افق‌های جدیدی را در پیش‌بینی قیمت سهام ایجاد کرده است (Kuna, 2022; Yang, 2024).

در ایران نیز پژوهش‌های متعددی به بررسی عوامل مؤثر بر بازده و قیمت سهام پرداخته‌اند. نتایج این مطالعات نشان می‌دهد که متغیرهای مالی، نسبت‌های حسابداری، ساختار شبکه‌ای بازار و شاخص‌های بهره‌وری سرمایه می‌توانند نقش مهمی در تبیین رفتار سهام ایفا کنند (Alimohammadpour et al., 2020; Taghizadeh & Abdzadeh Konafi, 2023). همچنین برخی پژوهش‌ها بر کاربرد روش‌های یادگیری ماشین و فراابتکاری در پیش‌بینی شوک‌های قیمتی و بازده سهام تأکید کرده‌اند و نشان داده‌اند که این روش‌ها در بسیاری از موارد عملکرد مطلوبی دارند (Ebadati et al., 2021; Fadaei et al., 2021). از سوی دیگر، تحقیقات انجام‌شده در بورس اوراق بهادار تهران نشان داده‌اند که انتخاب مناسب متغیرها و کاهش ابعاد داده‌ها می‌تواند تأثیر مهمی بر افزایش دقت مدل‌های پیش‌بینی داشته باشد (Setayesh & Kazemnejad, 2019). همچنین مطالعات جدیدتر بر اهمیت بهینه‌سازی مبتنی بر ریسک و استفاده از رویکردهای کارایی‌سنجی در پیش‌بینی بازده سهام تأکید کرده‌اند (Akhbari et al., 2024; Taslimpour et al., 2026).

با وجود پیشرفت‌های قابل توجه در توسعه مدل‌های پیش‌بینی، هنوز اجماع روش‌شناختی مشخصی درباره برترین روش برای پیش‌بینی قیمت سهام وجود ندارد. برخی مطالعات برتری الگوریتم‌های پیچیده یادگیری ماشین را گزارش کرده‌اند، در حالی که برخی دیگر نشان داده‌اند که مدل‌های ساده‌تر و تفسیرپذیرتر در داده‌های واقعی و خارج از نمونه عملکرد پایدارتری دارند (Akyildirim et al., 2022; Mansilla-Lopez, 2025; Sheth & Shah, 2023). علاوه بر این، بسیاری از پژوهش‌ها تمرکز خود را بر برازش درون‌نمونه‌ای قرار داده‌اند و کمتر به ارزیابی عملکرد واقعی مدل‌ها در داده‌های خارج از نمونه پرداخته‌اند؛ موضوعی که می‌تواند منجر به بیش‌برازش و کاهش قابلیت تعمیم نتایج شود (Dai et al., 2022; Saravanos & Kanavos, 2025; Tomar & Periyasamy, 2023). از این رو، مقایسه هم‌زمان

روش‌های مختلف غیرخطی و ارزیابی آن‌ها بر اساس داده‌های واقعی خارج از نمونه، می‌تواند در شناسایی مدل‌های کارآمدتر برای تصمیم‌گیری سرمایه‌گذاران و مدیران مالی نقش مهمی ایفا کند.

بنابراین، هدف این پژوهش بررسی عوامل مؤثر بر قیمت سهام و مقایسه کارایی روش‌های رگرسیون فازی، الگوریتم ژنتیک، ماشین بردار پشتیبان، درخت تصمیم و یادگیری ماشین در پیش‌بینی قیمت پایانی سهام با استفاده از داده‌های واقعی خارج از نمونه است.

## روش پژوهش

داده‌های مورد استفاده در این تحقیق، داده‌های روزانه سهام شرکت «فولاد اصفهان» در بازه زمانی ۲۰۲۴/۰۱/۰۱ الی ۲۰۲۵/۱۱/۱۹ شامل هر روز معاملاتی در این بازه می‌باشد. در طول بازه مذکور صرفاً تعداد بسیار محدودی از روزهایی که بعضی از داده‌ها موجود نبوده بطور کامل مورد استفاده قرار گرفته است. متغیرهای بکار رفته به شرح ذیل است:

قیمت بازگشایی، بالاترین قیمت، پایین‌ترین قیمت، آخرین معامله یا قیمت پایانی، قیمت تعدیلی، میزان تغییر، درصد تغییر، ارزش بازار، تعداد معاملات، حجم معاملات، ارزش معاملات، سهام شناور،  $\frac{P}{S}$ ،  $\frac{P}{B}$ ،  $\frac{P}{Ettm}$ ، قدرت خرید حقیقی، درصد خالص حقیقی، خالص حقیقی و سرانه خرید حقیقی یا سرانه فروش حقیقی.

در نهایت با توجه به اینکه بعضی از این متغیرهای همپوشانی دارند (مانند میزان تغییر و درصد تغییر و ...) و این امر موجب همخطی شدید<sup>۱</sup> می‌گردد، لذا متغیرهایی که منجر به این امر می‌شود را حذف و نهایتاً متغیرهای باقیمانده شامل قیمت پایانی، تعداد معاملات،  $\frac{P}{Ettm}$ ، درصد خالص حقیقی، سرانه خرید حقیقی و سرانه فروش حقیقی می‌باشند.

در نهایت با توجه به داده‌های مذکور و حجم بالای آن‌ها که می‌تواند کمک شایانی به تخمین بهتر داشته باشد، به پیش‌بینی قیمت سهام مذکور پرداخته می‌شود.

## یافته‌ها

در ادامه به بررسی روش‌های مورد استفاده در این تحقیق و نتایج حاصل از آن‌ها پرداخته می‌شود:

الگوریتم ژنتیک یک روش فراابتکاری مبتنی بر اصول تکامل طبیعی است که برای حل مسائل بهینه‌سازی غیرخطی و پیچیده به کار می‌رود. در این الگوریتم، هر راه‌حل به صورت یک کروموزوم نمایش داده شده و کیفیت آن با استفاده از تابع برازندگی  $f(X)$  سنجیده می‌شود. انتخاب افراد با احتمال متناسب با برازندگی آن‌ها انجام می‌گیرد ( $P_i = \frac{f_i}{\sum f_i}$ )، و عملگرهای تقاطع و جهش با هدف تولید نسل‌های جدید و جلوگیری از همگرایی زودرس اعمال می‌شوند. تکرار این فرایند منجر به همگرایی الگوریتم به سمت راه‌حل بهینه یا شبه‌بهینه می‌شود. به دلیل انعطاف‌پذیری بالا و عدم نیاز به فرض محدودکننده، الگوریتم ژنتیک به‌طور گسترده در مسائل مالی و بهینه‌سازی مدل‌های پیش‌بینی مورد استفاده قرار می‌گیرد. در ادامه به روش الگوریتم ژنتیک به پیش‌بینی قیمت پایانی و نیز میزان کارایی و دقت این روش اشاره خواهد شد. در اینجا نرخ جهش ده درصد لحاظ شده است. در ادامه و در جدول زیر (جدول ۱) متغیرهای معنادار و به ترتیب بیشترین تا کمترین اهمیت (اثر) آمده است.

<sup>1</sup> Multicollinearity



## جدول ۱

نتایج الگوریتم ژنتیک

متغیر	ضریب
درصد تغییر	۲۹۴.۸۷
P/B	۲۲.۵۸
P/S	-۱۹.۹۴
P/E	-۳.۲۲
قدرت خرید حقیقی	-۲.۴۱
بالاترین قیمت	۰.۵۸
پایین‌ترین قیمت	۰.۵۶
قیمت بازگشایی	-۰.۱۴
تعداد معاملات	۰.۰۱

در نهایت معادله کلی به صورت زیر است:

$$Y = \beta_0 + 294.87 (DT) + 22.58 (P/B) - 19.94 (P/S) - 3.22 (P/E) - 2.41 (GH KH H) + 0.58 (BGH) + 0.56 (PGH) - 0.14 (GHB) + 0.03 (TM)$$

همچنین میزان ضریب تعیین در این مدل بسیار بالا و نزدیک به ۱ است که عدد بالایی را نشان می‌دهد. منطق فازی یک رویکرد در شناخت متغیرها است که محاسبه چندین مقدار حقیقی را از طریق یک متغیر ممکن می‌سازد. منطق فازی تلاش می‌کند تا نتایج دقیقی از استدلال‌های نامعین و نامحدود از داده‌های اکتشافی را به دست آورد. در رگرسیون فازی، هر ضریب به صورت یک عدد فازی مثلثی بصورت زیر نشان داده می‌شود:

$$= (c_j, s_j) \tilde{\beta}_j$$

که به ترتیب مرکز ضریب (ضریب قطعی) و پهنای فازی (درجه عدم قطعیت) را نشان می‌دهند. مدل نهایی نیز

$$= \tilde{\beta}_0 + \sum_{j=1}^k \tilde{\beta}_j X_j \tilde{Y}$$

در ادامه به روش رگرسیون فازی به پیش‌بینی قیمت پایانی و نیز میزان کارایی و دقت این روش اشاره خواهد شد. در ادامه و در جدول زیر (جدول ۲) متغیرهای معنادار و به ترتیب بیشترین تا کمترین اهمیت (اثر) آمده است.

## جدول ۲

نتایج رگرسیون فازی

متغیر	مرکز ضریب
آخرین معامله	۴۹۲.۴۸
بالاترین قیمت	۳۰۰.۷۳
پایین‌ترین قیمت	۲۸۶.۳۳
قیمت بازگشایی	۸۱.۷۰
ارزش بازار	۷۰.۰۶

-۵۷.۴۱	P/S
-۳۰.۶۹	قیمت تعدیلی
۹.۵۹	P/B
۸.۰۴	ارزش معاملات
۷.۸۵	سراجه خرید حقیقی

در نهایت معادله کلی به صورت زیر است:

$$\hat{Y} = 492.48 (AM) + 300.73 (BGH) + 286.33 (PGH) + 11.70 (GHB) + 70.06 (AB) - 57.41 (P/S) - 30.69 (GHT) + 9.59 (P/B) + 8.04 (AMO) + 7.85 (SKHH)$$

همچنین میزان ضریب تعیین در این مدل بسیار بالا و نزدیک به ۱ است که عدد بالایی را نشان می‌دهد.

یادگیری ماشین تفسیرپذیر به دسته‌ای از مدل‌ها و تکنیک‌ها اطلاق می‌شود که به پژوهشگران امکان می‌دهد تأثیر متغیرهای ورودی بر خروجی مدل را به صورت صریح و شفاف درک کنند. در کاربردهای مالی که در آن‌ها قابلیت توضیح‌پذیری و پاسخ‌گویی از اهمیت بالایی برخوردار است، یادگیری ماشین تفسیرپذیر چارچوبی قابل اتکا برای دستیابی هم‌زمان به پیش‌بینی دقیق و تفسیر اقتصادی فراهم می‌کند. در ادامه به روش یادگیری ماشین تفسیرپذیر به پیش‌بینی قیمت پایانی و نیز میزان کارایی و دقت این روش اشاره خواهد شد. در ادامه و در جدول زیر (جدول ۳) متغیرهای معنادار و به ترتیب بیشترین تا کمترین اهمیت (اثر) آمده است.

### جدول ۳

نتایج یادگیری ماشین تفسیرپذیر

متغیر	ضریب
بالاترین قیمت	۴۳۹.۳۷
آخرین معامله	۳۲۵.۳۵
پایین‌ترین قیمت	۱۹۲.۳۷
قیمت بازگشایی	۱۴۶.۷۳
درصد خالص حقیقی	۵.۹۸
میزان تغییر	۴.۷۷
تعداد معاملات	-۲.۴۲
ارزش معاملات	۲.۲۸
سراجه فروش حقیقی	۱.۹۰
خالص حقیقی	۱.۵۵

در نهایت معادله کلی به صورت زیر است:



$$Y^{\wedge} = 439.37 (BGH) + 325.35 (AM) + 192.37 (PGH) + 146.73 (GHB) + 5.98 (DKHH) + 4.77 (MT) - 2.42 (TMO) + 2.28 (AMO) + 1.90 (SFH) + 1.55 (KHH)$$

همچنین میزان ضریب تعیین در این مدل بسیار بالا و نزدیک به ۱ است که عدد بالایی را نشان می‌دهد.

مجموع داده‌ها را با  $D$  نمایش داده و به شرطی که  $x_i \in R^d$  و  $y_i \in R$ ، درخت تصمیم‌گیری سعی می‌کند به صورت بازگشتی داده‌ها را به قسمی از هم جدا کند که در هر گره متغیرهای مستقل  $l$  به هم نزدیک شده همسان شوند. هر گره، زیر مجموعه‌ای از داده‌هاست که به صورت بازگشتی ساخته شده‌است. به‌طور دقیق‌تر در گره  $m$  اگر داده ما  $Q$  باشد، سعی می‌کنیم یک بعد از متغیرهایی وابسته را به همراه یک آستانه انتخاب کنیم و داده‌ها را برحسب این بعد و آستانه به دو نیم تقسیم کنیم، به قسمی که به‌طور متوسط در هر دو نیم متغیرهای مستقل یا  $l$  خیلی به هم نزدیک و همسان شده باشند. این بعد و آستانه را  $\theta = (j, t_m)$  نامیده می‌شود. دامنه  $j$  برابر است با  $1, \dots, d$  و  $t_m$  یک عدد صحیح است. مقدار  $Q$  برحسب  $\theta = (j, t_m)$  به دو بخش  $Q_{left}(\theta)$  و  $Q_{right}(\theta)$  به صورت زیر تقسیم می‌شود:

$$Q_{left}(\theta) = \{(x_i, y_i) \in Q / x_{i,j} \leq t_m\}$$

$$Q_{right}(\theta) = \{(x_i, y_i) \in Q / x_{i,j} > t_m\}$$

برای انتخاب متغیر وابسته و آستانه آن باید آن  $\theta$  را انتخاب کرد که ناخالصی داده را کم کند.

در ادامه به روش مدل درخت تصمیم به پیش‌بینی قیمت پایانی و نیز میزان کارایی و دقت این روش اشاره خواهد شد. بایستی اشاره کرد که در این روش ضرایب وجود ندارند و اهمیت متغیرها مورد بررسی قرار می‌گیرد. در ادامه و در جدول زیر (جدول ۴) متغیرهای معنادار و به ترتیب بیشترین تا کمترین اهمیت (اثر) آمده است.

#### جدول ۴

نتایج یادگیری ماشین تفسیرپذیر

متغیر	اهمیت
بالاترین قیمت	۰.۷۱۶
آخرین معامله	۰.۲۰۷
ارزش بازار	۰.۰۳۸
قیمت بازگشایی	۰.۰۳۶
پایین‌ترین قیمت	۰.۰۰۳
سایر متغیرها	فاقد اهمیت = ۰

نتایج به روشنی نشان می‌دهد که بیش از ۹۲٪ تصمیم‌های مدل فقط با دو متغیر بالاترین قیمت و آخرین معامله گرفته می‌شود. همچنین میزان ضریب تعیین در این مدل برابر با ۸۹٪ است که عدد بالایی را نشان می‌دهد.

ماشین بردار پشتیبان ( $SVM$ ) یک روش قدرتمند یادگیری ماشین است که برای طبقه‌بندی و پیش‌بینی مورد استفاده قرار می‌گیرد. این روش به ویژه برای داده‌های با ابعاد بالا و غیرخطی مناسب است.  $SVM$  به دنبال یافتن یک هایپرپلین<sup>۱</sup> بهینه است که داده‌ها را در فضای ویژگی‌ها به دو دسته تقسیم کند. در زمینه پیش‌بینی نرخ بازدهی سهام، هدف  $SVM$  شناسایی الگوهای موجود در داده‌های تاریخی و پیش‌بینی

<sup>1</sup> hyperplane

بازدهی آینده بر اساس ویژگی‌های مختلف است. فرض کنید که داده‌های ما شامل  $(n)$  نمونه و  $(m)$  ویژگی باشد. هر نمونه به صورت  $(x_i, y_i)$  تعریف می‌شود که در آن  $x_i \in \mathbb{R}^m$  ویژگی‌ها و  $y_i \in \{-1, +1\}$  برچسب کلاس است. هدف ما پیدا کردن یک هایپرپلین به شکل زیر است:

$$w^T x + b = 0$$

که در آن  $w$  و  $b$  به ترتیب وزن‌ها و بایاس (*bias*) هستند. SVM به دنبال حداکثر کردن حاشیه (*margin*) بین دو کلاس است. حاشیه به فاصله بین نزدیک‌ترین نقاط داده از هر کلاس به هایپرپلین گفته می‌شود. این حاشیه به صورت زیر تعریف می‌شود:

$$\text{margin} = \frac{2}{|w|}$$

برای حل مسئله SVM، تابع هدف زیر بهینه‌سازی می‌شود:

$$\min\{w, b\} = \frac{1}{2} |w|^2$$

$$y_i(w^T x_i + b) \geq 1, \text{ For all } i$$

این محدودیت‌ها تضمین می‌کنند که نقاط داده از هر کلاس در سمت صحیح هایپرپلین قرار دارند. در صورتی که داده‌ها خطی قابل تفکیک نباشند، می‌توانیم از هسته‌ها (*kernels*) استفاده کنیم تا داده‌ها را به فضایی با ابعاد بالاتر منتقل کنیم، جایی که داده‌ها ممکن است خطی قابل تفکیک باشند. در ادامه به روش ماشین بردار پشتیبانی به پیش‌بینی قیمت پایانی و نیز میزان کارایی و دقت این روش اشاره خواهد شد. در جدول زیر (جدول ۵) متغیرهای معنادار و به ترتیب بیشترین تا کمترین اهمیت (اثر) آمده است.

## جدول ۵

نتایج ماشین بردار پشتیبانی

متغیر	ضریب
آخرین معامله	۲۹۲.۰۱
بالاترین قیمت	۲۷۸.۳۳
پایین‌ترین قیمت	۲۷۴.۳۰
قیمت بازگشایی	۲۴۷.۴۴
ارزش معاملات	۱۸.۵۳
میزان تغییر	۱۵.۳۲
حجم معاملات	-۱۲.۰۵
تعداد معاملات	-۹.۱۳
قدرت خرید حقیقی	-۸.۵۰
P/B	۷.۸۶

در نهایت معادله کلی به صورت زیر است:



$$\hat{Y} = 292.01 (AM) + 278.33 (BGH) + 274.30 (PGH) + 247.44 (GHB) + 18.53 (AMO) + 15.32 (MT) - 12.05 (HM) - 9.13 (TM) - 1.50 (GHKHH) + 7.86 (P/B)$$

همچنین میزان ضریب تعیین در این مدل بسیار بالا و نزدیک به ۱ است که عدد بالایی را نشان می‌دهد.

در ادامه به مقایسه دقت پیش‌بینی روش‌های مورد استفاده در این تحقیق پرداخته می‌شود. برای اینکه دقت روش‌های مورد استفاده بررسی شود فرض شده است که داده‌های واقعی سی روز انتهایی فایل بعنوان داده‌های واقعی در نظر گرفته شده و سپس با توجه به ضرایب به دست آمده روش‌های قبل و مقادیر آنها به تخمین نتایج پرداخته شد. عبارت دیگر بهترین انطباق با مقدار واقعی قیمت در ۳۰ روز پایانی در نظر گرفته شده است. نتایج مربوط به دقت پیش‌بینی بر اساس معیارهای  $MAE^3$  و  $RMSE^2$  در جدول زیر (جدول ۶) آمده است.

## جدول ۶

مقایسه دقت کارایی روش‌های مختلف

مدل	MSE	RMSE	MAE
رگرسیون فازی	۹۹۶	۳۱	۲۶
یادگیری ماشین	۱,۵۶۷	۴۰	۳۲
درخت تصمیم	۵,۰۲۷	۷۱	۵۳
SVM	۲,۹۰۸,۸۷۵	۷۰۶	۱,۶۹۹
الگوریتم ژنتیک	۷,۴۱۹,۷۴۱	۲,۷۲۴	۲,۷۰۴

نتایج جدول مقایسه نشان می‌دهد که با در نظر گرفتن ۳۰ مشاهده ابتدای فایل به‌عنوان قیمت‌های واقعی، در بین روش‌های بکار رفته و داده‌های موجود، رگرسیون فازی دقیق‌ترین و پایدارترین روش پیش‌بینی قیمت پایانی است. همچنین روش یادگیری ماشین رتبه دوم در دقت پیش‌بینی را دارد. روش‌های درخت تصمیم، ماشین بردار پشتیبان و الگوریتم ژنتیک (به‌صورت مستقل) با افت محسوس دقت مواجه شده‌اند که بیانگر محدودیت آن‌ها در تعمیم به داده‌های واقعی خارج از نمونه است. به‌طور کلی، نتایج نشان می‌دهد مدل‌های تفسیرپذیر در پیش‌بینی کوتاه‌مدت قیمت سهام نسبت به روش‌های پیچیده‌تر کارایی بالاتری دارند. در ادامه دقت پیش‌بینی روش‌های مورد استفاده به لحاظ نموداری آمده است که در آن محور عمودی قیمت پایانی را نشان می‌دهد:

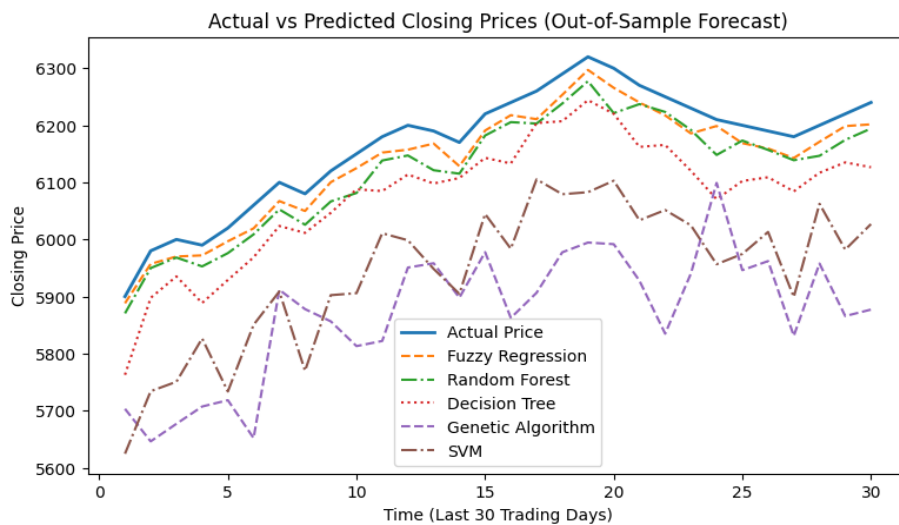
<sup>1</sup> Mean Squared Error

<sup>2</sup> Root Mean Squared Error

<sup>3</sup> Mean Absolute Error

## شکل ۱

مقایسه دقت پیش‌بینی مدل‌های مورد استفاده با داده‌های واقعی متغیر وابسته



## بحث و نتیجه‌گیری

هدف اصلی این پژوهش بررسی عوامل مؤثر بر قیمت سهام و مقایسه کارایی روش‌های پیشرفته غیرخطی شامل رگرسیون فازی، الگوریتم ژنتیک، ماشین بردار پشتیبان، درخت تصمیم و یادگیری ماشین در پیش‌بینی قیمت پایانی سهام بود. نتایج نشان داد که اگرچه تمامی مدل‌های مورد بررسی توانایی استخراج الگوهایی از داده‌های مالی را داشتند، اما تفاوت‌های معناداری در میزان دقت و قابلیت تعمیم آن‌ها به داده‌های واقعی خارج از نمونه مشاهده شد. مهم‌ترین یافته پژوهش آن بود که رگرسیون فازی کمترین میزان خطا و بیشترین پایداری را در پیش‌بینی قیمت سهام ارائه کرد و در رتبه نخست قرار گرفت. پس از آن، مدل یادگیری ماشین عملکرد مناسبی از خود نشان داد و توانست با فاصله‌ای نه‌چندان زیاد از رگرسیون فازی، قیمت‌های آتی را پیش‌بینی کند. در مقابل، الگوریتم ژنتیک و ماشین بردار پشتیبان با وجود برخورداری از برآزش مناسب در داده‌های آموزشی، در داده‌های واقعی خارج از نمونه عملکرد ضعیف‌تری داشتند و میزان خطای بیشتری را نشان دادند.

برتری رگرسیون فازی را می‌توان از چند منظر تبیین کرد. بازارهای مالی ماهیتی آکنده از عدم قطعیت، ابهام و اطلاعات ناقص دارند و بسیاری از روابط میان متغیرهای اقتصادی به صورت دقیق و قطعی قابل تعریف نیستند. منطق فازی دقیقاً برای مواجهه با چنین شرایطی طراحی شده است و به جای اتکا به مرزهای قطعی، از درجات عضویت و روابط انعطاف‌پذیر استفاده می‌کند. بنابراین، این روش می‌تواند بهتر از مدل‌های سخت و قطعی، رفتار واقعی بازار را بازتاب دهد. یافته حاضر با نتایج پژوهش‌هایی که بر اهمیت مدل‌سازی عدم قطعیت در بازارهای مالی تأکید کرده‌اند همسو است. برای مثال، پژوهش‌های انجام‌شده درباره رفتار غیرخطی بازده سهام و نوسانات شرطی بازارها نشان داده‌اند که مدل‌هایی که قادر به لحاظ کردن پیچیدگی و ابهام موجود در داده‌های مالی هستند، معمولاً عملکرد دقیق‌تری نسبت به مدل‌های خطی و قطعی دارند (Dhifaoui, 2022; Masini et al., 2023). همچنین یافته‌های پژوهش حاضر با نتایج مطالعاتی که بر ضرورت استفاده از رویکردهای انعطاف‌پذیر در محیط‌های مالی پیچیده تأکید کرده‌اند، سازگار است (Al Janabi, 2021; Mansilla-Lopez, 2025).



یافته دیگر پژوهش نشان داد که مدل یادگیری ماشین در رتبه دوم قرار دارد و عملکرد قابل قبولی در پیش‌بینی قیمت سهام ارائه می‌کند. این نتیجه با بخش قابل توجهی از ادبیات علمی موجود همسو است که یادگیری ماشین را به عنوان یکی از کارآمدترین ابزارهای تحلیل داده‌های مالی معرفی کرده‌اند. الگوریتم‌های یادگیری ماشین توانایی استخراج الگوهای پنهان و روابط غیرخطی میان متغیرها را دارند و می‌توانند حجم عظیمی از اطلاعات را به صورت همزمان پردازش کنند. پژوهش‌های متعددی نشان داده‌اند که این الگوریتم‌ها در مقایسه با بسیاری از مدل‌های سنتی دقت پیش‌بینی بیشتری ارائه می‌دهند (Hu et al., 2021; Sheth & Shah, 2023; Yang, 2024). همچنین مرورهای نظام‌مند حوزه پیش‌بینی مالی بیانگر آن است که پیشرفت‌های اخیر در یادگیری ماشین و یادگیری عمیق موجب ارتقای چشمگیر دقت پیش‌بینی سری‌های زمانی مالی شده است (Masini et al., 2023; Thakkar & Chaudhari, 2021). با این حال، نتایج پژوهش حاضر نشان داد که علی‌رغم توان بالای یادگیری ماشین، رگرسیون فازی در داده‌های واقعی خارج از نمونه عملکرد بهتری داشته است. این موضوع بیانگر آن است که پیچیدگی بیشتر مدل لزوماً به معنای دقت بیشتر در شرایط واقعی نیست.

یکی از نتایج قابل توجه پژوهش حاضر، عملکرد نسبتاً ضعیف ماشین بردار پشتیبان در مقایسه با انتظار نظری بود. در بسیاری از مطالعات، ماشین بردار پشتیبان به عنوان یکی از قدرتمندترین الگوریتم‌های پیش‌بینی معرفی شده است و توانسته نتایج مطلوبی در تحلیل بازارهای مالی ارائه دهد (Akyildirim et al., 2022; Tellez Gaytan et al., 2022). با این حال، یافته‌های پژوهش حاضر نشان داد که این مدل در داده‌های خارج از نمونه با افت عملکرد مواجه شده است. یکی از دلایل احتمالی این مسئله می‌تواند حساسیت بالای ماشین بردار پشتیبان به انتخاب پارامترها، نوع تابع هسته و ویژگی‌های داده‌ها باشد. در بازارهایی که ساختار داده‌ها دائماً در حال تغییر است، مدل‌های بسیار پیچیده ممکن است به داده‌های آموزشی بیش از حد وابسته شوند و در مواجهه با داده‌های جدید دچار ضعف تعمیم‌پذیری شوند. این تفسیر با دیدگاه پژوهشگرانی همسو است که نسبت به خطر بیش‌برازش در مدل‌های پیچیده یادگیری ماشین هشدار داده‌اند (Dai et al., 2022; Tomar & Periyasamy, 2023).

در خصوص الگوریتم ژنتیک نیز نتایج نشان داد که این روش پایین‌ترین رتبه را از نظر دقت پیش‌بینی به دست آورده است. اگرچه الگوریتم ژنتیک در بسیاری از مسائل بهینه‌سازی عملکرد موفقی داشته و در ترکیب با سایر الگوریتم‌ها نتایج مطلوبی ارائه کرده است (Ebadati et al., 2021; Kumar et al., 2022)، اما زمانی که به صورت مستقل برای پیش‌بینی قیمت سهام مورد استفاده قرار گیرد، ممکن است نتواند تمامی پیچیدگی‌های پویای بازار را به خوبی مدل‌سازی کند. همچنین الگوریتم ژنتیک به شدت تحت تأثیر نحوه تعریف تابع برازندگی، نرخ جهش و ساختار جمعیت اولیه قرار دارد و انتخاب نامناسب این پارامترها می‌تواند بر عملکرد نهایی آن اثرگذار باشد. بنابراین، نتایج پژوهش حاضر نشان می‌دهد که استفاده مستقل از الگوریتم ژنتیک برای پیش‌بینی قیمت سهام ممکن است کارایی محدودی داشته باشد و بهتر است در قالب مدل‌های ترکیبی مورد استفاده قرار گیرد.

یافته مهم دیگر این پژوهش، شناسایی متغیرهای کلیدی مؤثر بر قیمت سهام بود. نتایج نشان داد که متغیرهایی نظیر بالاترین قیمت، پایین‌ترین قیمت، قیمت بازگشایی و آخرین معامله در اغلب مدل‌ها دارای بیشترین اهمیت بودند. این نتیجه نشان می‌دهد که اطلاعات قیمتی کوتاه‌مدت همچنان مهم‌ترین منبع اطلاعاتی برای پیش‌بینی قیمت‌های آتی محسوب می‌شوند. این یافته با مطالعاتی که بر نقش نسبت‌های ارزش‌گذاری، روندهای قیمتی و شاخص‌های معاملاتی در پیش‌بینی بازده سهام تأکید کرده‌اند، همخوانی دارد (Tsai et al., 2024; Yang, 2023; Yu et al., 2023). همچنین نتایج پژوهش حاضر با مطالعاتی که نقش اطلاعات مدیریتی و سیگنال‌های بازار را در شکل‌گیری انتظارات سرمایه‌گذاران برجسته کرده‌اند، سازگار است (Birz et al., 2022; Kitagawa & Shuto, 2024).

از منظر نظری، یافته‌های این پژوهش تأییدکننده این دیدگاه هستند که بازارهای مالی دارای ساختاری پیچیده، پویا و غیرخطی هستند و مدل‌های خطی سنتی قادر به توضیح کامل رفتار آن‌ها نیستند. رفتار سرمایه‌گذاران، تغییرات محیطی، ریسک‌های ژئوپلیتیکی، اخبار اقتصادی و حتی عوامل روان‌شناختی همگی می‌توانند در شکل‌گیری قیمت سهام نقش داشته باشند. مطالعات مختلف نشان داده‌اند که سوگیری‌های شناختی، رفتارهای توده‌وار و واکنش‌های احساسی سرمایه‌گذاران می‌توانند موجب انحراف قیمت‌ها از ارزش‌های بنیادی شوند (Alqahtani et al., 2020; Ye et al., 2020). در چنین شرایطی، استفاده از مدل‌هایی که بتوانند پیچیدگی و عدم قطعیت را بهتر مدیریت کنند، ضرورت بیشتری پیدا می‌کند.

نتایج پژوهش حاضر همچنین از منظر عملی دارای اهمیت است. بسیاری از سرمایه‌گذاران و مدیران مالی تصور می‌کنند که استفاده از پیچیده‌ترین الگوریتم‌های هوش مصنوعی همواره منجر به بهترین نتایج خواهد شد. با این حال، یافته‌های این مطالعه نشان داد که مدل‌های تفسیرپذیر و نسبتاً ساده‌تر می‌توانند در شرایط واقعی بازار عملکردی حتی بهتر از مدل‌های بسیار پیچیده داشته باشند. این موضوع اهمیت تعادل میان دقت پیش‌بینی و قابلیت تفسیر را برجسته می‌سازد. پژوهش‌های جدید نیز بر این نکته تأکید کرده‌اند که مدل‌های قابل توضیح می‌توانند اعتماد بیشتری در میان تصمیم‌گیرندگان ایجاد کنند و کاربرد عملی گسترده‌تری داشته باشند (Mansilla-Lopez, 2025; Saravanos & Kanavos, 2025).

در مجموع، یافته‌های پژوهش حاضر ضمن تأیید قابلیت استفاده از روش‌های پیشرفته غیرخطی در پیش‌بینی قیمت سهام، نشان داد که کارایی این روش‌ها یکسان نیست و انتخاب مدل مناسب باید بر اساس ویژگی‌های داده‌ها، هدف تحلیل و میزان نیاز به تفسیرپذیری صورت گیرد. نتایج حاکی از آن است که رگرسیون فازی و یادگیری ماشین تفسیرپذیر در شرایط واقعی بازار عملکرد پایدارتر و قابل اتکاتری دارند، در حالی که مدل‌های پیچیده‌تر نظیر ماشین بردار پشتیبان و الگوریتم ژنتیک ممکن است با وجود برآزش مناسب در داده‌های آموزشی، در تعمیم به داده‌های جدید با محدودیت مواجه شوند. این یافته‌ها می‌توانند به توسعه چارچوب‌های تحلیلی مؤثرتر برای پیش‌بینی قیمت سهام و تصمیم‌گیری در بازار سرمایه کمک کنند (Akhbari et al., 2024; Lv & Qi, 2022; Taslimpour et al., 2026).

یکی از محدودیت‌های این پژوهش، استفاده از داده‌های مربوط به یک شرکت بورسی بود که ممکن است قابلیت تعمیم نتایج به سایر صنایع و شرکت‌ها را محدود کند. همچنین دوره زمانی مورد بررسی، اگرچه شامل تعداد قابل توجهی مشاهده بود، اما تمامی شرایط اقتصادی و چرخه‌های بلندمدت بازار را پوشش نمی‌داد. محدودیت دیگر به عدم استفاده از متغیرهای کلان اقتصادی، شاخص‌های روان‌شناختی سرمایه‌گذاران و داده‌های متنی مربوط به اخبار و شبکه‌های اجتماعی بازمی‌گردد که می‌توانند بر رفتار قیمت سهام اثرگذار باشند.

پیشنهاد می‌شود در پژوهش‌های آینده، مدل‌های مورد بررسی بر روی صنایع مختلف و تعداد بیشتری از شرکت‌های بورسی آزمون شوند تا امکان مقایسه بین‌بخشی فراهم گردد. همچنین استفاده از داده‌های کلان اقتصادی، شاخص‌های احساسات سرمایه‌گذاران، داده‌های شبکه‌های اجتماعی و متغیرهای ژئوپلیتیکی می‌تواند به بهبود دقت مدل‌های پیش‌بینی کمک کند. بررسی مدل‌های ترکیبی مبتنی بر ادغام رگرسیون فازی، یادگیری عمیق، یادگیری تقویتی و الگوریتم‌های فراابتکاری نیز می‌تواند مسیر ارزشمندی برای تحقیقات آتی باشد.

سرمایه‌گذاران، تحلیلگران مالی و مدیران سبد سرمایه‌گذاری می‌توانند از مدل رگرسیون فازی به عنوان یک ابزار قابل اعتماد برای پیش‌بینی کوتاه‌مدت قیمت سهام استفاده کنند. همچنین توصیه می‌شود در طراحی سامانه‌های هوشمند تحلیل بازار، علاوه بر دقت پیش‌بینی، قابلیت تفسیر و شفافیت مدل‌ها نیز مورد توجه قرار گیرد. شرکت‌های سرمایه‌گذاری و نهادهای مالی می‌توانند با بهره‌گیری از مدل‌های تفسیرپذیر، فرآیند ارزیابی ریسک و تصمیم‌گیری سرمایه‌گذاری را بهبود بخشند و از اتکای بیش از حد به الگوریتم‌های پیچیده و غیرشفاف اجتناب کنند.



## تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

## مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

## موازن اخلاقی

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

## شفافیت داده‌ها

داده‌ها و مآخذ پژوهش حاضر در صورت درخواست از نویسنده مسئول و ضمن رعایت اصول کپی رایت ارسال خواهد شد.

## حامی مالی

این پژوهش حامی مالی نداشته است.

## References

- Akhbari, H., Mohammadzadeh Salteh, H., Baradaran Hassanzadeh, R., & Zeinali, M. (2024). Optimization of Risk-Based Stock Return Forecasting in Selected Industries of the Tehran Stock Exchange: A Data Envelopment Analysis Approach. *Financial Research*, 26(2), 331-354.
- Akyildirim, E., Bariviera, A. F., Nguyen, D. K., & Sensoy, A. (2022). Forecasting High-Frequency Stock Returns: A Comparison of Alternative Methods. *Annals of Operations Research*, 313(2), 639-690. <https://doi.org/10.1007/s10479-021-04464-8>
- Al Janabi, M. A. (2021). Multivariate Portfolio Optimization under Illiquid Market Prospects: A Review of Theoretical Algorithms and Practical Techniques for Liquidity Risk Management. *Journal of Modelling in Management*, 16(1), 288-309. <https://doi.org/10.1108/JM2-07-2019-0178>
- Alimohammadpour, A., Faghani Makrani, K., & Zabihi, A. (2020). The Effect of Capital Productivity Management on Capital Asset Pricing Models with an Emphasis on the Life Cycle. *Productivity management*, 14(52).
- Alqahtani, A., Bouri, E., & Vo, X. V. (2020). Predictability of GCC Stock Returns: The Role of Geopolitical Risk and Crude Oil Returns. *Economic Analysis and Policy*, 68, 239-249. <https://doi.org/10.1016/j.eap.2020.09.017>
- Birz, G., Dutta, S., & Yu, H. (2022). Economic Forecasts, Anchoring Bias, and Stock Returns. *Financial management*, 51(1), 169-191. <https://doi.org/10.1111/fima.12355>
- Dai, Z., Li, T., & Yang, M. (2022). Forecasting Stock Return Volatility: The Role of Shrinkage Approaches in a Data-Rich Environment. *Journal of Forecasting*, 41(5), 980-996. <https://doi.org/10.1002/for.2841>
- Dhifaoui, Z. (2022). Determinism and Non-Linear Behaviour of Log-Return and Conditional Volatility: Empirical Analysis for 26 Stock Markets. *South Asian Journal of Macroeconomics and Public Finance*, 11(1), 69-94. <https://doi.org/10.1177/2277978721995654>
- Ebadati, O., Jafari, M. A., & Davoudifar, N. (2021). Stock Price Prediction in Financial Markets Using Hybrid GA-SVM Algorithms. *Advances in Finance and Investment*, 2(5), 1-22.
- Fadaei, E., Dadashi, I., Zare Behnamiri, M. J., & Azinfar, K. (2021). Prediction of Negative Stock Price Shock Based on a Metaheuristic Approach. *Financial Knowledge of Securities Analysis / Financial Studies*, 14(50), 99-108.
- Hu, Z., Zhao, Y., & Khushi, M. (2021). A Survey of Forex and Stock Price Prediction Using Deep Learning. *Applied System Innovation*, 4(1), 9. <https://doi.org/10.3390/asi4010009>
- Kitagawa, N., & Shuto, A. (2024). Unexpected Management Forecasts and Future Stock Returns. *Journal of Business Finance & Accounting*. <https://doi.org/10.1111/jbfa.12785>

- Kumar, G., Singh, U. P., & Jain, S. (2022). Swarm Intelligence Based Hybrid Neural Network Approach for Stock Price Forecasting. *Computational Economics*, 60(3), 991-1039. <https://doi.org/10.1007/s10614-021-10176-9>
- Kuna, S. S. (2022). Reinforcement Learning for Optimizing Insurance Portfolio Management. *African Journal of Artificial Intelligence and Sustainable Development*, 2(2), 289-334.
- Lv, W., & Qi, J. (2022). Stock Market Return Predictability: A Combination Forecast Perspective. *International Review of Financial Analysis*, 84, 102376. <https://doi.org/10.1016/j.irfa.2022.102376>
- Mansilla-Lopez, J. (2025). Factors, Forecasts, and Simulations of Volatility in the Stock Market Using Machine Learning. *Journal of Risk and Financial Management*. <https://doi.org/10.3390/jrfm18050227>
- Masini, R. P., Medeiros, M. C., & Mendes, E. F. (2023). Machine Learning Advances for Time Series Forecasting. *Journal of Economic Surveys*, 37(1), 76-111. <https://doi.org/10.1111/joes.12429>
- Saravanos, C., & Kanavos, A. (2025). Forecasting stock market volatility using social media sentiment analysis. *Neural Computing and Applications*, 37(17), 10771-10794.
- Setayesh, M. H., & Kazemnejad, M. (2019). Investigating the Usefulness of Variable Reduction Methods in Predicting Stock Returns of Companies Listed on the Tehran Stock Exchange. *Empirical Studies in Financial Accounting*, 16(63), 83-107.
- Sheth, D., & Shah, M. (2023). Predicting Stock Market Using Machine Learning: Best and Accurate Way to Know Future Stock Prices. *International Journal of System Assurance Engineering and Management*, 14(1), 1-18. <https://doi.org/10.1007/s13198-022-01811-1>
- Taghizadeh, R., & Abdzadeh Konafi, M. (2023). An Analysis of the Capital Market Using a Network Approach. *Financial Research*, 25(3).
- Taslimpour, A., Askarzadeh, G., Qalmaq, K., & Nasiri, H. (2026). Forecasting the Tehran Stock Exchange index using the NARX neural network model. *Asset Management and Financial Supply*, 14(1), 21-48. <https://doi.org/10.22108/amf.2025.143461.1940>
- Tellez Gaytan, J. C., Ateeq, K., Rafiuddin, A., Alzoubi, H. M., Ghazal, T. M., Ahanger, T. A., & Vijju, G. K. (2022). AI-Based Prediction of Capital Structure: Performance Comparison of ANN, SVM, and LR Models. *Computational Intelligence and Neuroscience*, 2022(1), 8334927. <https://doi.org/10.1155/2022/8334927>
- Thakkar, A., & Chaudhari, K. (2021). Fusion in Stock Market Prediction: A Decade Survey on the Necessity, Recent Developments, and Potential Future Directions. *Information Fusion*, 65, 95-107. <https://doi.org/10.1016/j.inffus.2020.08.019>
- Tomar, M., & Periyasamy, V. (2023). The Role of Reference Data in Financial Data Analysis: Challenges and Opportunities. *Journal of Knowledge Learning and Science Technology*, 1(1), 90-99. <https://doi.org/10.60087/jklst.vol1.n1.p99>
- Tsai, H. W., Che, H. C., & Bai, B. (2024). Exploring the Relationship Between Patent Forward Citation and Stock Return Rate Using Empirical Data of China Stock Market. *Management*, 12(2), 67-83. <https://doi.org/10.17265/2328-2185/2024.02.001>
- Yang, H. (2024). Multimodal Stock Price Forecasting Using Attention Mechanism Based on Multi-Task Learning. *Lecture Notes in Computer Science*, 14332, 454-468. [https://doi.org/10.1007/978-981-97-2390-4\\_31](https://doi.org/10.1007/978-981-97-2390-4_31)
- Yang, J. (2023). Analysis of Influencing Factors of Stock Return Rate. *Highlights in Business, Economics and Management*, 21, 394-399. <https://doi.org/10.54097/hbem.v21i.14495>
- Ye, J., Li, D., & Cao, Y. (2020). Investor Irrational Selection Bias in Stock Market Based on Cognitive Psychology: Evidence from Herding Behaviour. *Revista Argentina de Clínica Psicológica*, 29(1), 90.
- Yu, D., Huang, D., & Chen, L. (2023). Stock Return Predictability and Cyclical Movements in Valuation Ratios. *Journal of Empirical Finance*, 72, 36-53. <https://doi.org/10.1016/j.jempfin.2023.02.004>