



Predictability of the Tehran Exchange Dividend and Price Index Using a Combined Machine Learning Approach: Market Efficiency Analysis and Importance of Influential Variables

Amirhossein Heydari Delooei

MSc Student, Department of Algorithms and Computation, Faculty of Engineering Sciences, College of Engineering, University of Tehran, Tehran, Iran. E-mail: amirheydari.ut@gmail.com

Masoud Vahdati

MSc., Department of Finance, Faculty of Accounting and Finance, College of Management, University of Tehran, Tehran, Iran. E-mail: vahdati.m@ut.ac.ir

Hossein Mohebbi

Assistant Prof., Department of Industrial Management, Faculty of Humanities, Meybod University, Meybod, Iran. E-mail: hossein.mohebbi@meyu.ir

Negin Bagherpour*

*Corresponding Author, Assistant Prof., Department of Algorithms and Computation, Faculty of Engineering Sciences, College of Engineering, University of Tehran, Tehran, Iran. E-mail: negin.bagherpour@ut.ac.ir

Abstract

Objective

This study aims to evaluate the efficiency of the Iranian capital market and examine the capability of hybrid machine learning models in predicting the direction of the Tehran Exchange Dividend and Price Index (TEDPIX). Additionally, the study seeks to assess the importance of influential factors affecting predictability and explainability within machine learning models.

Citation: Heydari Delooei, Amirhossein; Vahdati, Masoud; Mohebbi, Hossein & Bagherpour, Negin (2026). Predictability of the Tehran Exchange Dividend and Price Index Using a Combined Machine Learning Approach: Market Efficiency Analysis and Importance of Influential Variables. *Financial Research Journal*, 28(2), 464- 493. <https://doi.org/10.22059/FRJ.2025.394747.1007738> (in Persian)



Methods

To analyze market efficiency at weak and semi-strong levels, data concerning the Tehran Exchange Dividend and Price Index from five years (2019 to 2023) is utilized. The proposed combined model includes an Extreme Gradient Boosting (XGBoost) model that is enhanced through hyperparameter optimization via a Genetic Algorithm (GA). The performance of this combined model is statistically compared against other machine learning algorithms, including XGBoost, Random Forest, Support Vector Machine, and Logistic Regression. Furthermore, to enhance the model's explainability and analyze the importance of input variables in predicting the index direction, the SHAP (Shapley Additive Explanations) method is employed.

Results

The results indicate that the XGBoost-GA model outperforms other comparative models statistically, achieving an accuracy of 84% in predicting the direction of the Tehran Exchange Dividend and Price Index. A comparison of the results across different levels of market efficiency indicates that, at the semi-strong level, incorporating fundamental variables into the predictive model enhances forecasting accuracy. This finding reflects the influence of fundamental information on predicting the direction of the index and, consequently, suggests the presence of market inefficiency at this level. Additionally, at the weak-form level, the machine learning model based on technical data outperformed the random model, indicating the existence of market inefficiency at this level as well. Moreover, the model's explainability analysis, using SHAP, showed that the impact of variables on predicting the index direction varies based on the type of input data. In the purely technical model, factors related to price behavior and short-term fluctuations, such as the Relative Strength Index (RSI), trading volume, and moving average divergence and convergence, played a key role. In contrast, in the combined model that includes both fundamental and technical data, besides technical variables, factors such as real and legal liquidity influx, gold prices, and company financial indicators such as Return on Assets (RoA) and Return on Equity (RoE) significantly influenced predictions.

Conclusion

The results of the study demonstrate that the Iranian capital market is inefficient at both weak and semi-strong levels, and the predictability of the Index is achievable using both technical and fundamental data. The analysis of input variable significance indicates that certain technical, fundamental, and macroeconomic indices play a more crucial role in predicting market behavior, which can contribute to more informed investment decisions and a better understanding of machine learning models' behavior in forecasting financial time series.

Keywords: Extreme gradient boosting, Genetic algorithm, Machine learning explainability, Market efficiency theory, Tehran exchange dividend and price index.

پیش‌بینی‌پذیری شاخص کل بورس اوراق بهادار تهران با رویکرد یادگیری ماشین ترکیبی:

تحلیل کارایی بازار و اهمیت متغیرهای مؤثر

امیرحسین حیدری دلوائی

دانشجوی کارشناسی ارشد، گروه الگوریتم‌ها و محاسبات، دانشکده علوم مهندسی، دانشکدگان فنی، دانشگاه تهران، تهران، ایران. رایانامه: amirheydari.ut@gmail.com

مسعود وحدتی

کارشناس ارشد، گروه مالی، دانشکده مالی و حسابداری، دانشکدگان مدیریت، دانشگاه تهران، ایران. رایانامه: vahdati.m@ut.ac.ir

حسین محبی

استادیار، گروه مدیریت صنعتی، دانشکده علوم انسانی، دانشگاه میبد، میبد، ایران. رایانامه: hossein.mohebbi@meyu.ir

نگین باقرپور*

* نویسنده مسئول، استادیار، گروه الگوریتم‌ها و محاسبات، دانشکده علوم مهندسی، دانشگاه تهران، ایران. رایانامه: negin.bagherpour@ut.ac.ir

چکیده

هدف: این پژوهش با هدف سنجش کارایی بازار سرمایه ایران و بررسی توانایی مدل‌های یادگیری ماشین ترکیبی، برای پیش‌بینی جهت شاخص کل بورس اوراق بهادار تهران اجرا شده است. همچنین، ارزیابی میزان اهمیت عوامل مؤثر بر پیش‌بینی‌پذیری شاخص و توضیح‌پذیری در مدل‌های یادگیری ماشینی، از دیگر اهداف این مطالعه است.

روش: به منظور تحلیل کارایی بازار در دو سطح ضعیف و نیمه‌قوی، از داده‌های مربوط به شاخص کل بورس تهران، در بازه زمانی پنج‌ساله، از ۱۳۹۸ تا ۱۴۰۳ استفاده شده است. مدل ترکیبی پیشنهادی، شامل مدل‌های گرادینان تقویت شده (XGBoost) است که با بهینه‌سازی هایپرپارامترها، از طریق الگوریتم ژنتیک (GA) بهبود یافته است. عملکرد این مدل ترکیبی با سایر الگوریتم‌های یادگیری ماشین، شامل گرادینان تقویت شده، جنگل تصادفی، ماشین بردار پشتیبان و رگرسیون لجستیک از لحاظ آماری مقایسه شده است. همچنین، برای افزایش توضیح‌پذیری مدل و تحلیل میزان اهمیت متغیرهای ورودی برای پیش‌بینی جهت شاخص، از روش شاپ استفاده شده است.

یافته‌ها: نتایج نشان داد که مدل XGBoost-GA نسبت به سایر مدل‌های مقایسه‌ای، از لحاظ آماری، برای پیش‌بینی جهت شاخص کل بورس تهران با دقت ۸۴ درصد، عملکرد بهتری دارد. مقایسه نتایج در سطوح مختلف کارایی بازار نشان داد که در سطح نیمه‌قوی، افزودن متغیرهای بنیادی به مدل پیش‌بینی، موجب بهبود دقت شد که بیانگر تأثیر اطلاعات بنیادی بر پیش‌بینی جهت حرکت شاخص و در نتیجه،

استناد: حیدری دلوائی، امیرحسین؛ وحدتی، مسعود؛ محبی، حسین و باقرپور، نگین (۱۴۰۵). پیش‌بینی‌پذیری شاخص کل بورس اوراق بهادار تهران با رویکرد یادگیری ماشین ترکیبی: تحلیل کارایی بازار و اهمیت متغیرهای مؤثر. *تحقیقات مالی*، ۲۸(۲)، ۴۶۴-۴۹۳.

ناکارایی بازار در این سطح است. همچنین، در سطح ضعیف، مدل یادگیری ماشین مبتنی بر داده‌های تکنیکال، عملکرد بهتری نسبت به مدل تصادفی داشت که این امر نیز نشانه‌ای از ناکارایی بازار در این سطح محسوب می‌شود. علاوه بر این، تحلیل توضیح‌پذیری مدل با استفاده از شاپ نشان داد که تأثیر متغیرها در پیش‌بینی جهت شاخص، بسته به نوع داده‌های ورودی، متفاوت است. در مدل فقط تکنیکال، عوامل مرتبط با رفتار قیمتی و نوسان‌های کوتاه‌مدت مانند شاخص قدرت نسبی (RSI)، حجم معاملات و واگرایی و همگرایی میانگین متحرک نقش کلیدی داشتند. در مقابل، در مدل ترکیبی که شامل داده‌های بنیادی و تکنیکال بود، علاوه بر متغیرهای تکنیکال، عواملی مانند ورود نقدینگی حقیقی و حقوقی، قیمت طلا و شاخص‌های مالی شرکت‌ها نظیر بازده دارایی‌ها و بازده حقوق صاحبان سهام تأثیر چشمگیری داشتند.

نتیجه‌گیری: نتایج پژوهش نشان می‌دهد که بازار سرمایه ایران در هر دو سطح ضعیف و نیمه‌قوی ناکاراست و قابلیت پیش‌بینی‌پذیری شاخص کل با استفاده از داده‌های تکنیکال و بنیادی امکان‌پذیر است. تحلیل اهمیت متغیرهای ورودی نشان می‌دهد که برخی شاخص‌های تکنیکال، بنیادی و کلان اقتصادی نقش مهم‌تری در پیش‌بینی رفتار بازار دارند که این موضوع می‌تواند به تصمیم‌گیری‌های سرمایه‌گذاری آگاهانه‌تر و درک بهتر رفتار مدل‌های یادگیری ماشین در پیش‌بینی سری‌های زمانی مالی کمک کند.

کلیدواژه‌ها: نظریه کارایی بازار، الگوریتم ژنتیک، توضیح‌پذیری یادگیری ماشین، تقویت گرادیان شدید، شاخص کل بورس تهران.

مقدمه

بورس تهران به‌عنوان بازار مالی اصلی کشور، در جذب سرمایه نقش مهمی دارد. تحلیل و پیش‌بینی روندهای آن، ابزار تصمیم‌گیری مؤثری برای کاهش ریسک سرمایه‌گذاری است. از این‌رو، کارایی بازارهای مالی، موضوعی کلیدی در اقتصاد و سیاست‌گذاری مالی به‌شمار می‌رود. (عباسی، محمدی مقدم و قالیباف اصل، ۱۴۰۳). نظریه کارایی بازار^۱ بیان می‌کند که قیمت‌های دارایی‌ها به‌طور کامل و فوری تمامی اطلاعات موجود را منعکس می‌کنند، به‌گونه‌ای که هیچ سرمایه‌گذاری نمی‌تواند به‌صورت پایدار بازدهی بالاتر از میانگین بازار کسب کند (دیمیتریادو، گوگاس، پادامیتریو و پلاکانداراس^۲، ۲۰۱۸). بر اساس این نظریه، بازارهای مالی از نظر میزان انعکاس اطلاعات در قیمت‌های دارایی‌ها به سه سطح کارایی ضعیف، نیمه‌قوی و قوی تقسیم می‌شوند (فاما و فرنچ^۳، ۲۰۲۰). با وجود تأکید نظریه کارایی بازار بر عدم امکان پیش‌بینی سیستماتیک قیمت‌های دارایی‌ها، شواهد تجربی متعدد نشان داده‌اند که بازارهای مالی، به‌ویژه در اقتصادهای در حال توسعه، الزاماً از کارایی کامل برخوردار نیستند. این ناکارایی فرصتی را فراهم کرده است که با تحلیل داده‌های تاریخی و شرایط بازار، الگوهای پیش‌بینی‌پذیری استخراج شود (کائو، گدیکلی و ورانکس^۴، ۲۰۲۴). این یافته‌ها موجب شده‌اند تا پژوهشگران و فعالان حوزه بورس اوراق بهادار، به‌سمت استفاده از روش‌های نوین و پیشرفته برای ارزیابی کارایی بازار و پیش‌بینی حرکات آینده قیمت‌ها گرایش پیدا کنند (رودین^۵، ۲۰۱۹). مدل‌های یادگیری ماشینی به‌عنوان ابزارهای قدرتمند در تحلیل داده‌های مالی معرفی شده‌اند. به‌ویژه الگوریتم‌های مبتنی بر تقویت‌گرادیان نظیر XGBoost^۶ به‌دلیل توانایی در پردازش حجم وسیعی از داده‌های مالی و کشف روابط پیچیده و الگوهای غیرخطی، قابلیت ارائه دقت بالا در پیش‌بینی رفتار بازارهای مالی را دارند (چن و گسترین^۷، ۲۰۱۶). با این حال، یکی از چالش‌های اساسی در به‌کارگیری این روش‌ها، عدم شفافیت و تفسیرپذیری نتایج حاصل از مدل‌های یادگیری ماشینی پیچیده است (لیبتون^۸، ۲۰۱۸). این مدل‌ها عمدتاً دارای عملکرد «جعبه سیاه»^۹ هستند؛ به این معنا که تأثیر متغیرهای ورودی بر خروجی مدل به وضوح مشخص نیست و فرایند شکل‌گیری روابط بین این متغیرها در نتایج نهایی ناواضح باقی می‌ماند. این چالش می‌تواند به کاهش اعتماد سرمایه‌گذاران و تحلیل‌گران به مدل‌های مبتنی بر هوش مصنوعی منجر شود و محدودیت‌هایی در کاربرد عملی این مدل‌ها در دنیای واقعی ایجاد کند (مولنار^{۱۰}، ۲۰۲۵).

بنابراین، توسعه و به‌کارگیری روش‌های هوش مصنوعی توضیح‌پذیر، به‌عنوان پاسخی به این چالش‌ها و ارزیابی کارایی مدل‌های پیش‌بینی در بازارهای مالی، به یکی از مباحث کلیدی و ضروری در حوزه تحلیل داده‌های مالی تبدیل

1. Efficient Market Hypothesis
2. Dimitriadou, Gogas, Papadimitriou & Plakandaras
3. Fama & French
4. Cao, Gedikli & Vranx
5. Rudin
6. Extreme Gradient Boosting
7. Chen & Guestrin
8. Lipton
9. Black box
10. Molnar

شده است (گو، کلی و شیو^۱، ۲۰۲۰). تحقیقات جاری باید روی این توانایی‌ها متمرکز شوند که چگونه می‌توان ضمن بهره‌گیری از قدرت پیش‌بینی مدل‌های یادگیری ماشین، شفافیت و قابل درک بودن آن‌ها را نیز بهبود بخشید. در این زمینه، نیاز به پژوهش‌های بیشتر در خصوص بهینه‌سازی این مدل‌های یادگیری ماشینی با استفاده از الگوریتم‌های پیشرفته تکاملی و همچنین استفاده از چارچوب‌های توضیح‌پذیر به‌طور خاص در بورس اوراق بهادار تهران به‌منظور اطمینان بیشتر به نتایج، احساس می‌شود.

حال، سؤال اصلی پژوهش حاضر این است که آیا مدل ترکیبی یادگیری ماشینی XGBoost^۲ که بهینه‌سازی‌های مقدار هایپرپارامترهای خود را با استفاده از الگوریتم ژنتیک^۳ دریافت کرده است، می‌تواند حرکت شاخص کل بورس اوراق اوراق بهادار تهران^۴ را نسبت به مدل‌های قبلی با دقت پیش‌بینی بیشتری کند؟ همچنین، پژوهش حاضر، به بررسی امکان بهبود کارایی بورس، از طریق کارایی نیمه‌قوی و ضعیف می‌پردازد. علاوه‌براین، بررسی تأثیر متغیرهای ورودی و اهمیت نسبی ویژگی‌های مختلف در پیش‌بینی‌های مدل، به شفافیت علمی بیشتر در عرصه تحلیل بازار و تصمیم‌گیری سرمایه‌گذاری‌ها کمک شایانی خواهد کرد. این در حالی است که مسئله موجود در تحقیقات قبلی، کم‌توجهی به مدل‌های توضیح‌پذیر و تأثیر آن بر شفافیت و اعتبار پیش‌بینی‌هاست.

این پژوهش با هدف به‌کارگیری مؤثر هوش مصنوعی در ارزیابی کارایی بازارهای مالی، به‌ویژه بورس تهران، می‌کوشد تا دقت مدل‌های یادگیری ماشین را با شفافیت در تحلیل متغیرها تلفیق کند. هدف، ارائه الگویی قابل تفسیر و کاربردی برای بهبود تصمیم‌گیری در حوزه سرمایه‌گذاری، سیاست‌گذاری مالی و مدیریت ریسک است.

پیشینه نظری پژوهش

در دهه‌های اخیر، جذابیت بازار سهام به‌ویژه با ظهور فناوری‌های تحلیلی پیشرفته، رشد بی‌سابقه‌ای داشته است. سرمایه‌گذاران خصوصی و نهادی، با تکیه بر روش‌های نوینی مانند یادگیری ماشین، در پی شناسایی الگوهای پنهان در داده‌های مالی برای کسب بازدهی تعدیل‌شده با ریسک هستند (ذوقی، راعی و فلاح‌پور، ۱۴۰۱)؛ اما این تلاش‌ها پرسش بنیادینی را به ذهن متبادر می‌کند: اگر الگوریتم‌ها بتوانند به‌طور مداوم بازدهی بیشتری پیش‌بینی کنند، آیا این به‌معنای نقض فرضیه کارایی بازار است؟ فرضیه‌ای که نخستین بار توسط یوجین فاما مطرح شد و ادعا می‌کند که قیمت‌داری‌ها تمام اطلاعات موجود را فوری و کامل منعکس می‌کند و هیچ بازدهی اضافی بدون پذیرش ریسک بالاتر ممکن نیست (آتی و ایمبنس^۵، ۲۰۱۹). فاما و فرنچ سه سطح مختلف از کارایی بازار را معرفی کردند (فاما و فرنچ، ۲۰۲۰):

- در سطح کارایی ضعیف^۶، تمامی اطلاعات تاریخی قیمت‌ها در ارزش‌داری‌ها منعکس شده است، بنابراین تحلیل تکنیکال نمی‌تواند سودی فراتر از بازدهی بازار ایجاد کند.

1. Gu, Kelly & Xiu
 2. Extreme Gradient Boosting
 3. Genetic Algorithm
 4. Tehran Exchange Dividend and Price Index
 5. Athey & Imbens
 6. Weak-form Efficiency

- در سطح کارایی نیمه‌قوی^۱، علاوه بر اطلاعات تاریخی قیمت، تمامی اطلاعات عمومی نظیر داده‌های بنیادی شرکت‌ها نیز در قیمت‌ها لحاظ شده است؛ به گونه‌ای که تحلیل بنیادی نیز نمی‌تواند مزیتی برای سرمایه‌گذاران ایجاد کند.
 - در نهایت، در سطح کارایی قوی^۲، حتی اطلاعات محرمانه و درونی شرکت‌ها نیز پیش‌تر در قیمت‌های دارایی‌ها منعکس شده است که در این صورت، هیچ راهبردی نمی‌تواند به کسب بازدهی مازاد منجر شود.
- با این حال، مطالعات متعدد نشان داده‌اند که بازارها در عمل ممکن است از کارایی کامل فاصله داشته باشند. برای مثال، مالی رفتاری با معرفی سوگیری‌های شناختی و هیجانات سرمایه‌گذاران، توضیح می‌دهد که چرا قیمت‌ها گاهی از منطقی اقتصادی فاصله می‌گیرند و فرصت‌های سودآوری غیرمنطقی ایجاد می‌شود. این تناقض میان نظریه و واقعیت، نیاز به ابزارهای تحلیلی قدرتمندی دارد که نه تنها توانایی پیش‌بینی، بلکه قابلیت شناسایی نقاط ناکارایی را نیز داشته باشند (تالر^۳، ۲۰۱۶).
- در این راستا، هوش مصنوعی و به‌ویژه یادگیری ماشین، به‌عنوان موتور محرک تحولات اخیر در تحلیل مالی ظهور کرده است. این فناوری‌ها با توانایی کشف روابط غیرخطی و الگوهای پیچیده در داده‌های سری زمانی مالی، مرزهای جدیدی را در پیش‌بینی قیمت‌ها گشوده‌اند (ژانگ، لی و وانگ^۴، ۲۰۲۴). یادگیری ماشین، شاخه‌ای از هوش مصنوعی است که مدل‌ها را قادر می‌سازد تا بر اساس داده‌های ورودی آموزش ببینند و روابط میان متغیرها را به‌طور خودکار استخراج کنند. این حوزه به سه دسته اصلی تقسیم می‌شود: یادگیری نظارت‌شده، یادگیری بدون نظارت و یادگیری تقویتی (شولت^۵، ۲۰۲۱). الگوریتم XGBoost یکی از روش‌های پیشرفته در یادگیری نظارت‌شده است که بر اساس تقویت گرادیان توسعه یافته است. این الگوریتم با بهره‌گیری از درخت‌های تصمیم تقویت‌شده و تکنیک‌های پیشرفته کنترل بیش‌برازش مانند ارزیابی متقاطع به یکی از ابزارهای کلیدی در مدل‌سازی مالی تبدیل شده است؛ اما قدرت واقعی این مدل‌ها در گرو ترکیب هوشمندانه سه دسته ورودی است: متغیرهای تکنیکال، بنیادی – کلان اقتصادی و تحلیل اخبار. این ترکیب، تصویری چندبعدی از بازار ارائه می‌دهد که می‌تواند هم برای پیش‌بینی و هم برای آزمون کارایی بازار به کار رود (ژونگ و انکه^۶، ۲۰۱۹).
- در ارزیابی دقت مدل‌های یادگیری ماشین در پیش‌بینی قیمت سهام، معیارهای مختلفی بسته به نوع مسئله وجود دارد که عمدتاً به دو دسته تقسیم می‌شوند: پیش‌بینی مقدار و پیش‌بینی جهت. پیش‌بینی مقدار شامل ارزیابی دقت مدل در پیش‌بینی مقدار دقیق قیمت سهام است، در حالی که پیش‌بینی جهت شامل ارزیابی دقت مدل در پیش‌بینی جهت حرکت قیمت سهام (افزایش یا کاهش) است (ژانگ و همکاران، ۲۰۲۴). برای ارزیابی عملکرد مدل‌های طبقه‌بندی، از

1. Semi-strong form Efficiency
2. Strong-form Efficiency
3. Thaler
4. Zhang, Li & Wang
5. Chollet
6. Zhong & Enke

ماتریس درهم‌ریختگی^۱ استفاده می‌شود که بررسی می‌کند مدل تا چه حد در پیش‌بینی دقیق روندهای افزایشی و کاهش‌ی قیمت سهام موفق عمل کرده است (حسن، رحمان و کیم،^۲ ۲۰۲۳). این ابزار به تحلیلگران اجازه می‌دهد تا نقاط قوت و ضعف مدل را در پیش‌بینی‌های مختلف ارزیابی کنند. پایایی نتایج در طول زمان و توانایی تفسیر منطق تصمیم‌گیری مدل نیز به همان اندازه حیاتی است؛ چرا که اعتبارسنجی تجربی فرضیه‌های مالی را مستلزم شفافیت و تکرارپذیری می‌دانند. بنابراین، پایایی نتایج در مواجهه با داده‌های جدید که با روش‌هایی مانند ارزیابی متقاطع^۳ سری‌زمانی سنجیده می‌شود و توضیح‌پذیری مدل، دو رکن اساسی برای اعتمادسازی هستند (برگمیر، هایندمن و بنیتز،^۴ ۲۰۲۳). در اینجا، تکنیک‌هایی مانند SHAP^۵ (با محاسبه اهمیت جهانی ویژگی‌ها بر پایه نظریه بازی‌ها) و LIME^۶ (با ایجاد مدل‌های محلی تفسیرپذیر) وارد عمل می‌شوند و شفافیت تصمیم‌گیری مدل را افزایش می‌دهند (لاندبرگ و همکاران،^۷ ۲۰۲۰). به بیان دیگر، ترکیب XGBoost با چارچوب‌های توضیح‌پذیری، پنجره‌ای نوین به‌سوی ارزیابی کارایی بازار می‌گشاید. اگر مدل بتواند جهت یا مقدار قیمت را با دقت زیاد پیش‌بینی کند، آن هم بر پایه عواملی که در چارچوب نظریه کارایی بازار (EMH) نباید تأثیری سیستماتیک داشته باشند، می‌توان شواهدی تجربی از ناکارایی بازار ارائه داد. از سوی دیگر، تفسیرپذیری مدل نشان می‌دهد کدام دسته از متغیرها بیشترین نقش را در پیش‌بینی و ناکارایی بازار در سطوح مختلف را داشته‌اند.

پیشینه تجربی

مطالعات گسترده‌ای در حوزه ارزیابی کارایی بازارهای مالی با استفاده از روش‌های پیشرفته اقتصادسنجی و یادگیری ماشین انجام شده است که هر یک با تمرکز بر جنبه‌های متفاوتی از این پدیده، به نتایج متنوعی دست یافته‌اند. پژوهش‌های اولیه عمدتاً بر مدل‌های کلاسیک اقتصادسنجی مانند آریما^۸ و آزمون‌های آماری مبتنی بر فرضیه کارایی بازار متمرکز بودند، اما با ظهور فناوری‌های تحلیلی نوین، استفاده از الگوریتم‌های یادگیری ماشین نظیر شبکه‌های عصبی عمیق به‌طور فزاینده‌ای رواج یافته است (آتی و ایمبس،^۹ ۲۰۲۱). برای نمونه، مطالعات بین‌المللی گذشته همچون پژوهش‌های لو و مک‌کینلی^۹ (۱۹۸۸) در شناسایی ناکارایی‌های بازار با استفاده از آزمون‌های واریانس یا کاربرد الگوریتم‌های ترکیبی توسط فاما و فرنچ (۲۰۲۰) در پیش‌بینی بازدهی سهام، نشان داده‌اند که انتخاب مدل و داده‌ها بر تفسیر کارایی بازار تأثیر مستقیمی دارد. برخی پژوهش‌ها مانند مطالعه اتسالاکیس و والوانیس^{۱۰} (۲۰۰۹) در پیش‌بینی

1. Confusion Matrix
2. Hassan, Rahman & Kim
3. Cross-validation
4. Bergmeir, Hyndman & Benítez
5. SHapley Additive exPlanations
6. Local Interpretable Model-Agnostic Explanations
7. Lundberg et al.
8. AutoRegressive Integrated Moving Average (ARIMA)
9. Lo & MacKinlay
10. Etsalakis & Valavanis

شاخص‌های مالی با استفاده از شبکه‌های عصبی نشان می‌دهند که مدل‌های غیرخطی یادگیری ماشین می‌توانند بازدهی بالاتری نسبت به روش‌های سنتی داشته باشند، در حالی که تحقیقات دیگری مانند شوبایو، آدیمی لانگه، پوپولا و اوکویگیبو^۱ (۲۰۲۵) هشدار می‌دهند که افزایش پیچیدگی مدل‌ها ممکن است به بیش‌برازش و کاهش تفسیرپذیری بینجامد. در این راستا، جدول ۱ با رویکردی سیستماتیک، خلاصه‌ای از پژوهش‌های شاخص داخلی و بین‌المللی را ارائه می‌دهد.

جدول ۱. پیشینه پژوهش

اطلاعات پژوهش	نویسندگان
<p>عنوان: بررسی تأثیر مداخلات دولتی در دوران کووید ۱۹ بر نوسان‌های بازار سهام</p> <p>مدل‌های یادگیری ماشین: گرادیان تقویتی سبک، حافظه طولانی کوتاه‌مدت، تقویت گرادینانی افزایشی، تقویت دسته‌ای، جنگل تصادفی، رگرسیون بردار پشتیبان، رگرسیون خطی</p> <p>بازه نمونه‌گیری: داده‌های روزانه از ژانویه ۲۰۲۰ تا سپتامبر ۲۰۲۱ (۴۱۹ مشاهده)</p> <p>ورودی‌های مدل: شاخص‌های مداخلات دولتی، شاخص پاسخ دولت، شاخص سخت‌گیری مقررات</p> <p>شاخص حمایت اقتصادی شاخص محدودیت‌ها و بهداشت شاخص ریسک بازگشایی داده‌های بازار سهام چین (بازده و نوسان)</p> <p>یافته‌ها: با به‌کارگیری توضیح‌پذیری مدل، متوجه شدند نوسان‌های بازار بیشتر تحت تأثیر مداخلات دولتی بوده و LightGBM بهترین عملکرد را در پیش‌بینی داشته است.</p>	<p>یانگ، عابدین، ونگ و هاجک^۲ (۲۰۲۵)</p>
<p>عنوان: یادگیری ماشینی توضیح‌پذیر در مدیریت ریسک اعتباری</p> <p>مدل‌های یادگیری ماشین: XGBoost</p> <p>بازه نمونه‌گیری: بررسی ۱۵۰۴۵ شرکت کوچک و متوسط در سال ۲۰۱۵</p> <p>ورودی‌های مدل: بازده حقوق صاحبان سهام مرتبط با سود قبل از مالیات و بهره، سود قبل از کسر مالیات و بهره. اهرم مالی مرتبط با مجموع دارایی‌ها و حقوق صاحبان سهام. نسبت نقدینگی مرتبط با حساب‌های دریافتی تجاری. سود قبل از بهره، مالیات، استهلاک و تخفیف. کل دارایی‌ها به کل بدهی‌ها</p> <p>یافته‌ها: این پژوهش با توضیح‌پذیری سیستم‌های مدیریت ریسک اعتباری، یافته‌های مهمی برای تصمیم‌گیرندگان و سیاست‌گذاران بانکی که در تلاش‌اند تا از مصرف‌کنندگان خدمات هوش مصنوعی محافظت کنند، ارائه می‌دهد.</p>	<p>بوسمان، جودیچی، مارینلی و پاپنبروک^۳ (۲۰۲۱)</p>
<p>عنوان: پیش‌بینی روند بازار سهام چین</p> <p>مدل‌های یادگیری ماشین: ماشین بردار پشتیبان، جنگل تصادفی و شبکه عصبی مصنوعی</p> <p>بازه نمونه‌گیری: ژانویه ۲۰۱۱ تا ژانویه ۲۰۱۸ / روزانه</p> <p>ورودی‌های مدل: معیارهای ارزش‌گذاری، معیارهای رشد، معیارهای مالی و سودآوری، معیارهای بدهی، معیارهای مومنتوم تکنیکال، معیارهای نوسان، معیارهای نقدشوندگی و سایر معیارهای تکنیکال</p> <p>یافته‌ها: بهترین عملکرد زمانی به دست می‌آید که از RF برای هر دو انتخاب ویژگی و پیش‌بینی روند قیمت سهام استفاده شود.</p>	<p>یوان، یوان، جیانگ و آین^۴ (۲۰۲۰)</p>

1. Shobayo, Adeyemi-Longe, Popoola & Okoyeigbo
2. Yang, Abedin, Zhang, Weng & Hajek
3. Busmann, Giudici, Marinelli & Papenbrock
4. Yuan, Yuan, Jiang & Ain

اطلاعات پژوهش	نویسندگان
<p>عنوان: بررسی قدرت مدل‌های مبتنی بر هوش مصنوعی در پیش‌بینی روند قیمت سهام بورس اوراق بهادار تهران</p> <p>مدل‌های یادگیری ماشین: مدل‌های خطی، مدل‌های خودهم‌بسته مانند آریمما، جنگل تصادفی و شبکه‌های عصبی مثل شبکه عصبی پیش‌خور و مدل حافظه طولانی کوتاه‌مدت</p> <p>بازه نمونه‌گیری: ۱۳۹۰ تا ۱۳۹۹/روزانه</p> <p>ورودی‌های مدل: شاخص‌های تکنیکال و برخی شاخص‌های اقتصاد کلان</p> <p>یافته‌ها: مدل‌های مبتنی بر یادگیری عمیق عملکرد بهتری از خود نشان می‌دهند و در پیش‌بینی روند کوتاه‌مدت و همچنین روند منفی سهام قیمت سهام از دقت بالاتری برخوردارند.</p>	حیدری و امیری (۱۴۰۱)
<p>عنوان: مقایسه مدل‌های مختلف یادگیری ماشین در پیش‌بینی شاخص بازار سهام</p> <p>مدل‌های یادگیری ماشین: جنگل تصادفی، ماشین بردار پشتیبان، شبکه عصبی مصنوعی و شبکه عصبی بازگشتی</p> <p>بازه نمونه‌گیری: ۱۳۹۲ تا ۱۳۹۹/روزانه</p> <p>ورودی‌های مدل: شاخص کل بورس تهران، لگاریتم شاخص S&P، لگاریتم شاخص بورس فلزات امارات، لگاریتم نفت خام اوپک، لگاریتم نرخ ارز آزاد بازار، لگاریتم قیمت اونس طلا، لگاریتم قیمت سکه بهار آزادی</p> <p>یافته‌ها: روش یادگیری ماشین مبتنی بر شبکه عصبی بازگشتی حافظه طولانی کوتاه‌مدت در مقایسه با سایر مدل‌های مورد بررسی دقت و عملکرد بهتری داشت.</p>	سهرابی، میربرگ‌کار، چیرانی و خردیار (۱۴۰۱)
<p>عنوان: پیش‌بینی جهت بازار در معاملات آتی سکه با استفاده از مدل‌های یادگیری عمیق</p> <p>مدل‌های یادگیری ماشین: حافظه طولانی کوتاه‌مدت با خودرمز نگار انباشته، جنگل تصادفی</p> <p>بازه نمونه‌گیری: داده‌های ۱۵ دقیقه‌ای از بازار آتی سکه ایران و بازار جهانی طلا</p> <p>ورودی‌های مدل: MACD, RSI, ATR, BOLL, CCI، نسبت خریدار به فروشنده</p> <p>یافته‌ها: مدل پیشنهادی LSTM عملکرد بهتری نسبت به روش‌های کلاسیک داشت.</p>	ذوقی و همکاران (۱۴۰۱)
<p>عنوان: تفسیر پیش‌بینی بازده شاخص قیمت صنایع تولیدی بورس اوراق بهادار تهران با استفاده از یادگیری تجمیعی توضیح‌پذیر</p> <p>مدل‌های یادگیری ماشین: جنگل تصادفی با الگوریتم ژنتیک</p> <p>بازه نمونه‌گیری: ۱۳۹۷ تا ۱۴۰۲/روزانه</p> <p>ورودی‌های مدل: متغیرهای تکنیکال، بنیادی و کلان اقتصادی</p> <p>یافته‌ها: متغیرهای تکنیکال، به ویژه شاخص میانگین متحرک نمایی، حجم معاملات و میزان سهام شناور، بیشترین نقش را در بهبود دقت پیش‌بینی ایفا می‌کنند. در مقابل، متغیرهای بنیادی همچون نسبت قیمت به درآمد و نرخ بهره و نرخ تورم تأثیرگذارند، اما نقش آن‌ها نسبت به متغیرهای تکنیکال کمتر است.</p>	راعی، واحدتی، محبی و حیدری دلویی (۱۴۰۳)

این پژوهش با هدف پُر کردن خلأ موجود در ادبیات، چارچوبی مقایسه‌پذیر ارائه می‌دهد که برای نخستین بار در بورس تهران، کارایی بازار را با ترکیب دقت پیش‌بینی و توضیح‌پذیری مدل‌های یادگیری ماشین ارزیابی می‌کند. این رویکرد، با شفاف‌سازی نقش متغیرها در مکانیسم‌های ناکارایی، محدودیت مطالعات پیشین در تبیین عوامل مؤثر را رفع می‌کند و الگویی نوین برای تحقیقات آتی در پیوند یادگیری ماشین و بازارهای مالی فراهم می‌سازد.

روش‌شناسی پژوهش

این پژوهش کاربردی با رویکرد توصیفی - تحلیلی و پیش‌بینی کمی، به ارزیابی کارایی بورس تهران در سطوح ضعیف و نیمه‌قوی می‌پردازد. برای این منظور، از چارچوبی ترکیبی مبتنی بر یادگیری ماشین و هوش مصنوعی توضیح‌پذیر استفاده شده است. داده‌ها شامل اطلاعات بنیادی و تکنیکال شاخص‌ها در بازه زمانی ۱۳۹۸ تا ۱۴۰۳، از بورس‌ویو استخراج شده‌اند. تحلیل داده‌ها با پایتون و در محیط ژوپیترا انجام شده است. ابتدا دقت مدل XGBoost-GA با مدل‌های ساده‌تر مقایسه می‌شود؛ سپس کارایی نیمه‌قوی و ضعیف بازار با بررسی تأثیر داده‌های بنیادی و تکنیکال ارزیابی می‌شود. در پایان، با استفاده از مقادیر شاپ، نقش متغیرها در پیش‌بینی‌ها شفاف‌سازی و رتبه‌بندی خواهد شد. در ادامه، چارچوب اجرای پژوهش به تفصیل توضیح داده خواهد شد.

پیش‌پردازش داده‌ها

برای ارزیابی کارایی بازار، ابتدا داده‌ها پیش‌پردازش شده و متغیرهای ورودی به دو دسته تکنیکال و بنیادی تفکیک شدند. در سطح ضعیف، تنها متغیرهای تکنیکال مانند میانگین متحرک و RSI به کار رفتند. در سطح نیمه‌قوی، متغیرهای بنیادی نیز مانند نسبت‌های مالی و سود سهام اضافه شد. کاهش ابعاد داده‌ها با روش تحلیل مؤلفه‌های اصلی انجام شد. سپس با مقایسه مقدار شاخص هر روز با روز قبل، برچسب +۱ یا -۱ برای مدل‌سازی اختصاص یافت. علاوه بر این، به منظور ارزیابی عملکرد مدل‌ها، داده‌ها با استفاده از روش ارزیابی متقاطع^۱ سری‌های زمانی به پنج بخش تقسیم شده‌اند. در هر بخش از ارزیابی متقاطع، ۸۰ درصد داده‌ها به عنوان مجموعه آموزشی و ۲۰ درصد به عنوان مجموعه آزمون در نظر گرفته می‌شود. این روش به محققان این امکان را می‌دهد که عملکرد مدل را در شرایط واقعی بازار در زمان‌های متفاوت و با سناریوهای مختلف بیازمانند و از پدیده‌ای به نام بیش‌برازش^۲ جلوگیری کنند. با این رویکرد، مدل می‌تواند عملکرد خود را در شرایط مختلف بازار به درستی ارزیابی کند و دقت پیش‌بینی‌ها از پایایی لازم برخوردار باشد (اسمیت، جانسون و لی^۳، ۲۰۲۳). در جدول ۲ تمامی فیچرهای ورودی مدل یادگیری ماشین بیان شده است.

جدول ۲. فیچرهای ورودی مدل یادگیری ماشین

متغیرهای بنیادی سهام، رفتاری سهام‌داران و کلان اقتصادی	اطلاعات قیمتی بازار و شاخص‌های تکنیکال
۱. ارزش بازار بر حسب دلار آزاد MktUSD (Market in USD)	۱. ارزش ریالی بورس اوراق بهادار تهران MkVal (Market Value)
۲. ارزش بازار بر حسب دلار نیمایی MktNIA (Market in NIMA)	۲. بازده لگاریتمی شاخص کل بورس اوراق بهادار تهران Index (Return of the TSE Index)
۳. درصد شناوری بورس تهران FIRt (Float Rate)	۳. حجم معاملات بورس اوراق بهادار تهران TrVol (Transaction Volume)
۴. ارزش خالص ورود پول اشخاص حقیقی صندوق با درآمد ثابت NF-FD (Net Flow Fixed Debt)	۴. ارزش معاملات بورس اوراق بهادار تهران TrVal (Transaction Value)

1. Cross-Validation (CV)
2. Overfitting
3. Smith, Johnson & Lee

متغیرهای بنیادی سهام، رفتاری سهام‌داران و کلان اقتصادی	اطلاعات قیمتی بازار و شاخص‌های تکنیکال
۵. ارزش خالص ورود یا خروج پول اشخاص حقیقی به بورس تهران NFIIn (Net Flow In)	۵. میانگین متحرک ساده (۱۰، ۲۰، ۵۰ روزه) Simple Moving Average (SMA)
۶. ارزش خالص ورود یا خروج پول اشخاص حقوقی به بورس تهران NCIn (Net Corporate In)	۶. میانگین متحرک نمایی (۱۰، ۲۰، ۵۰ روزه) Exponential Moving Average (EMA)
۷. بازده دارایی‌ها شرکت‌های پذیرفته‌شده RoA (Return on Assets)	۷. شاخص قدرت نسبی (۱۴ روزه) Relative Strength Index (RSI)
۸. بازده حقوق صاحبان سهام شرکت‌ها RoE (Return on Equity)	۸. واگرایی و همگرایی میانگین متحرک (۱۴، ۳۰، ۵۰ روزه) MACD
۹. درصد تقسیم سود شرکت‌ها DpS% (Dividend Share %)	۹. انحراف معیار (۱۴، ۳۰، ۵۰ روزه) Standard Deviation (SD)
۱۰. ارزش خالص ورود یا خروج پول اشخاص حقیقی به صندوق‌های طلا NF-G (Net Flow Gold)	۱۰. حجم متوازن (۱۴، ۲۱، ۳۰ روزه) On-Balance Volume (OBV)
۱۱. قیمت لگاریتمی صندوق طلا لوتوس در بورس LTF-Price (Lotus Gold Fund Price)	۱۱. حجم قیمت (۱۴، ۲۱، ۳۰ روزه) Volume Price Trend (VPT)
۱۲. نرخ بهره بدون ریسک RFRate (Risk-Free Rate)	
۱۳. نرخ دلار نیمایی NIRate (NIMA Rate)	
۱۴. نرخ دلار آزاد FDRate (Free Dollar Rate)	
۱۵. قیمت به ارزش دفتری (p/b-ttm) PB-TTM (Price to Book TTM)	
۱۶. قیمت به درآمد فروش (p/s-ttm) PS-TTM (Price to Sales TTM)	
۱۷. قیمت به سود خالص (p/e-ttm) PE-TTM (Price to Earnings TTM)	
۱۸. ارزش بنگاه به سود قبل از بهره و مالیات (EV/EBIT) (Enterprise Value to EBIT)	
۱۹. قیمت به سود نقدی (p/d) (Price to Dividend)	

مدل تقویت گرادیان شدید

مدل XGBoost که توسط چن و گوسترین^۱ در سال ۲۰۱۶ توسعه داده شده است، یکی از الگوریتم‌های یادگیری ترکیبی بسیار کارآمد است که به‌طور گسترده‌ای در یادگیری ماشین و داده‌کاوی مورد استفاده قرار می‌گیرد. XGBoost شامل مجموعه‌ای از طبقه‌بندهای ضعیف است که به‌صورت خطی با یک طبقه‌بند نسبتاً قوی‌تر ترکیب می‌شوند. این مدل به‌خاطر دقت زیاد، قدرت عمومی‌سازی قوی و سرعت محاسباتی سریع خود، به‌عنوان یک رویکرد برجسته در یادگیری ماشین شناخته می‌شود (لی و ژانگ^۲، ۲۰۱۹). در پژوهش حاضر، از مدل XGBoost برای پیش‌بینی جهت تغییرات شاخص کل بورس اوراق بهادار تهران استفاده می‌شود. برای این منظور، پیش‌بینی به‌صورت رابطه^۱ تعریف می‌شود (دنگ، هوانگ، ژو، سو، فو و شیمادا^۳، ۲۰۲۳):

1. Chen and Guestrin
2. Li & Zhang
3. Deng, Huang, Zhu, Su, Fu & Shimada

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad \text{رابطه ۱}$$

که در آن \hat{y}_i نتیجه پیش‌بینی شده، f_k امتیاز برای k امین یادگیرنده ضعیف و K تعداد یادگیرنده‌های ضعیف است. هدف اصلی در ساخت این مدل، یافتن پارامترهای بهینه با کمینه کردن تابع هدف است. تابع هدف XGBoost شامل دو بخش است:

$$Obj = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad \text{رابطه ۲}$$

در این معادله، l تابع ضرر و Ω عملگر منظم‌سازی مدل است. بخش اول به اندازه‌گیری تفاوت‌های بین پیش‌بینی و هدف واقعی می‌پردازد و بخش دوم برای مجازات ساختار پیچیده درخت‌های تصمیم طراحی شده است. عملگر منظم‌سازی با رابطه ۳ تعریف می‌شود:

$$\Omega(f) = \gamma T + \frac{1}{2} \gamma \sum_{i=1}^T w_i^2 \quad \text{رابطه ۳}$$

که در آن γ پارامتر پیچیدگی، T تعداد کل گره‌های برگ و λ ضریب منظم‌سازی است. مدل‌سازی در XGBoost به صورت افزایشی و با افزودن یک تابع جدید $f_t(x_i)$ برای بهبود مدل فعلی و تعیین یک تابع ضرر جدید صورت می‌گیرد. بنابراین، تابع هدف با رابطه ۴ بیان می‌شود:

$$Obj^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad \text{رابطه ۴}$$

فرایند بهینه‌سازی در این مدل شامل محاسبه وزن‌های بهینه گره‌های برگ و تابع ضرر در گره‌های برگ است که به صورت رابطه‌های ۵ و ۶ بیان می‌شوند:

$$w_j^* = - \frac{\sum_{i \in I_j} g_j}{\sum_{i \in I_j} h_j + \lambda} \quad \text{رابطه ۵}$$

و

$$w_j^* = - \frac{\sum_{i \in I_j} g_j}{\sum_{i \in I_j} h_j + \lambda} \quad \text{رابطه ۶}$$

برای تصمیم‌گیری در مورد تشخیص برچسب داده‌های پیش‌بینی در این مدل، از تابع Gain استفاده می‌شود که با رابطه ۷ تعریف می‌شود:

$$Gain = \frac{1}{2} \left(\frac{(\sum_{i \in I_L} g_j)^2}{\sum_{i \in I_L} h_j + \lambda} + \frac{(\sum_{i \in I_R} g_j)^2}{\sum_{i \in I_R} h_j + \lambda} - \frac{(\sum_{i \in I} g_j)^2}{\sum_{i \in I} h_j + \lambda} \right) - \gamma \quad (\text{رابطه ۷})$$

علاوه بر این، انتخاب هایپرپارامترها در XGBoost بر دقت پیش‌بینی تأثیر چشمگیری دارد. عموماً، در جریان فرایند آموزش مدل، از یک روش بهینه‌سازی عمومی به نام جست‌وجوی شبکه‌ای^۱ برای پیدا کردن بهترین ترکیب هایپرپارامترها استفاده خواهد شد. در این پژوهش، برای بهینه‌سازی بهتر هایپرپارامترها از الگوریتم ژنتیک به‌عنوان یک الگوریتم تکاملی به‌جای روش‌های رایج مثل جست‌وجوی شبکه‌ای استفاده شده است.

بهینه‌سازی هایپرپارامترها با الگوریتم ژنتیک

بهینه‌سازی هایپرپارامترها یکی از مراحل کلیدی در ساخت و بهبود مدل‌های یادگیری ماشین است. برای مثال تنظیم تعداد دفعاتی که مدل خودش را بهبود می‌دهد، حداکثر عمق درخت‌ها، سرعت یادگیری به‌عنوان هایپرپارامترهای مدل شناخته می‌شود. در این پژوهش، از الگوریتم ژنتیک به‌عنوان یک روش بهینه‌سازی مؤثر برای تعیین بهترین مقادیر هایپرپارامترهای مدل XGBoost استفاده می‌شود. مراحل بهینه‌سازی هایپرپارامترها بر مبنای الگوریتم ژنتیک شامل چهار مرحله زیر است (سیواناندام و دیپا، ۲۰۰۸):

۱. تولید تصادفی جمعیت اولیه‌ای از کروموزوم‌ها (ترکیب‌های مختلف هایپرپارامترها) و ارزیابی عملکرد آن‌ها.
۲. انتخاب بهترین کروموزوم‌ها بر اساس دقت مدل.
۳. اعمال ترکیب و جهش برای ایجاد نسل‌های جدید و متنوع.
۴. تکرار این چرخه تا رسیدن به ترکیب بهینه نهایی از هایپرپارامترها.

ارزیابی مدل

در ادامه، برای ارزیابی عملکرد مدل، به دو جنبه‌ی کلیدی ارزیابی متقاطع و معیارهای دقت پرداخته خواهد شد.

تعمیم‌پذیری زمانی مدل به‌وسیله ارزیابی متقاطع

یکی از چالش‌های اساسی در پیش‌بینی سری‌های زمانی، ارزیابی میزان پایداری و تعمیم‌پذیری مدل است. در این پژوهش، برای سنجش دقت و استحکام مدل، از روش ارزیابی متقاطع مبتنی بر بخش‌بندی سری زمانی استفاده شد. این شیوه به‌ویژه در مسائل پیش‌بینی سری‌های زمانی، جایگزین کارآمدتری نسبت به جداسازی داده‌های اعتبارسنجی^۳ است؛ زیرا از نشت اطلاعات آینده به مدل جلوگیری می‌کند و شرایط واقعی بازار را بهتر شبیه‌سازی می‌کند. مزیت اصلی این روش آن است که هیچ‌گونه داده‌ای از آینده در مجموعه آموزشی قرار نمی‌گیرد؛ بنابراین به شبیه‌سازی شرایط واقعی بازار منتج می‌شود.

1. Grid Search
2. Sivanandam & Deepa
3. validation set

با اعمال فرایند ارزیابی متقاطع در چندین بازه زمانی و بررسی عملکرد مدل در هر مرحله، می‌توان مطابق با رابطه‌های ۸ و ۹ به تعادلی میان بایاس (اختلاف میانگین دقت مدل در بخش‌ها با کل مدل) و واریانس (تغییرپذیری دقت مدل در بخش‌های مختلف) دست یافت. برابری میانگین دقت و واریانس پایین دقت بخش‌های مختلف، نشان‌دهنده تعمیم‌پذیری مطلوب مدل است (برار^۱، ۲۰۱۸):

$$\text{Bias}(\hat{\theta}) = (n - 1)(\bar{\theta} - \hat{\theta}) \quad \text{رابطه ۸}$$

$\text{bias}(\hat{\theta})$ معیار بایاس برای ارزیابی متقاطع؛ n تعداد بخش‌بندی ارزیابی متقاطع و $(\bar{\theta} - \hat{\theta})$ میزان انحراف میانگین دقت‌ها از دقت در هر یک از بخش‌های مختلف.

$$\text{Var}(\hat{\theta}) = \frac{n - 1}{n} \sum_{i=1}^n (\bar{\theta} - \hat{\theta}_i)^2 \quad \text{رابطه ۹}$$

$\text{Var}(\hat{\theta})$ معیار بایاس برای ارزیابی متقاطع؛ n تعداد بخش‌بندی ارزیابی متقاطع و $(\bar{\theta} - \hat{\theta}_i)$ میزان انحراف میانگین دقت‌ها از دقت در هر یک از بخش‌های مختلف.

دقت مدل یادگیری ماشین

در این بخش، توانایی مدل یادگیری ماشین در پیش‌بینی جهت حرکت شاخص بورس تهران، با استفاده از ماتریس درهم‌ریختگی برای محاسبه معیارهای دقت و F1 مورد ارزیابی قرار می‌گیرد.

دقت یکی از معیارهای اصلی برای ارزیابی عملکرد با رابطه ۱۰ محاسبه می‌شود (دنگ و همکاران، ۲۰۲۳):

$$\text{Accuracy} = \frac{\text{Number of correct 1 predictions} + \text{Number of correct 0 predictions}}{\text{Total number of direction prediction}} \quad \text{رابطه ۱۰}$$

در این رابطه، Number of correct '1' predictions به تعداد پیش‌بینی‌های صحیحی اشاره دارد که مدل، حرکت صعودی شاخص را پیش‌بینی کرده است. Number of correct '0' predictions نیز تعداد پیش‌بینی‌های صحیحی است که مدل، حرکت نزولی شاخص را درست تشخیص داده است. Total number of direction predictions به مجموع کل پیش‌بینی‌ها اشاره دارد. F1-score به‌عنوان یک معیار مکمل برای دقت در نظر گرفته می‌شود. F1-score از طریق رابطه ۱۱ محاسبه می‌شود (دنگ و همکاران، ۲۰۲۳):

$$F1 = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad \text{رابطه ۱۱}$$

در اینجا، معیار Precision مشخص می‌کند که از میان نمونه‌هایی که مدل آن‌ها را به‌عنوان مثبت پیش‌بینی کرده است، چه تعداد به درستی مثبت بوده‌اند. به بیان دیگر، Precision نشان می‌دهد که پیش‌بینی‌های مثبت مدل تا چه اندازه قابل اعتماد هستند.

در مقابل، معیار Recall بیانگر آن است که از میان تمام نمونه‌های مثبت واقعی، چه تعداد به درستی توسط مدل شناسایی شده‌اند. این معیار نشان می‌دهد که مدل تا چه حد در یافتن تمام موارد مثبت موفق عمل کرده است. به‌طور کلی، Precision و Recall در بسیاری از مسائل دچار رابطه‌ای معکوس هستند؛ یعنی افزایش یکی می‌تواند به کاهش دیگری منجر شود. برای ایجاد تعادل میان این دو معیار، از شاخص F1 Score استفاده می‌شود که میانگین موزون آن‌ها را محاسبه کرده و به‌عنوان یک معیار کلی برای سنجش عملکرد مدل به کار می‌رود.

رویکرد توضیح‌پذیری با مقادیر شاپ

تفسیر خروجی مدل‌های پیش‌بینی، عنصر کلیدی در فرایند مدل‌سازی است که به افزایش اعتماد کاربران به نتایج کمک می‌کند. در این پژوهش، از روش SHAP بهره می‌بریم تا اهمیت متغیرها را با استفاده از تئوری بازی‌های مشارکتی بسنجیم. روش مقادیر شاپ با هدف تحلیل تأثیر هر متغیر بر خروجی مدل، تمامی زیرمجموعه‌های ممکن از متغیرها را مدنظر قرار می‌دهد و بر تخصیص منصفانه ارزش ایجادشده در یک ائتلاف متمرکز است. مقدار شاپلی هر ورودی برابر است با سهم هر عامل در میانگین ارزش افزوده‌ای که هر بازیکن به زیرمجموعه‌ها اضافه می‌کند. مطابق با رابطه ۱۲، این مقادیر برای هر متغیر خاص در یک مدل با N متغیر ورودی و تابع ارزش v محاسبه می‌شود (استرامبلج و کونونکو، ۲۰۱۴):

$$\phi_i(v) = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(|N| - |S| - 1)!}{|N|!} [v((S \cup \{i\})) - v(S)] \quad \text{رابطه ۱۲}$$

$\phi_i(v)$ مقدار شاپلی برای بازیکن i ؛ N تعداد کل بازیکنان؛ S زیرمجموعه‌ای از بازیکنان به غیر از بازیکن i ؛ $|S|$: تعداد اعضای زیرمجموعه S ؛ $v((S \cup \{i\})) - v(S)$ ارزش افزوده‌ای که بازیکن i به ائتلاف S اضافه می‌کند. ضریبی که نشان‌دهنده احتمال وقوع ترتیب‌های مختلف است. $\frac{|S|!(|N| - |S| - 1)!}{|N|!}$

یافته‌های پژوهش

در این بخش، ابتدا عملکرد مدل ترکیبی XGBoost بهینه‌شده با الگوریتم ژنتیک در پیش‌بینی جهت حرکت شاخص کل بورس با مدل‌های رایج مقایسه می‌شود. سپس، با بررسی هم‌زمان کارایی ضعیف و نیمه‌قوی، مشخص خواهد شد که آیا ترکیب اطلاعات گذشته شاخص و داده‌های بنیادی و تکنیکال، نسبت به مدل‌های تصادفی یا صرفاً تکنیکال، بازدهی بیشتری دارد یا خیر. در پایان، با فرض نبود کارایی، نقش و اهمیت متغیرهای ورودی در مدل یادگیری ماشین تفسیر و رتبه‌بندی می‌شود.

بنابراین در راستای سؤال اصلی پژوهش، سه سؤال فرعی مطرح می‌شود که یافته‌های آن به شرح ذیل است:

۱. **برتری مدل پیشنهادی:** آیا مدل ترکیبی XGBoost بهینه‌سازی شده با الگوریتم ژنتیک، در پیش‌بینی جهت حرکت شاخص کل بورس اوراق بهادار تهران، به‌طور معنادار عملکردی بهتر از مدل‌های مرسوم دارد؟

برای ارزیابی عملکرد، مجموعه‌ای از مدل‌های یادگیری ماشین شامل رگرسیون لجستیک، جنگل تصادفی، ماشین بردار پشتیبان و نسخه ساده الگوریتم تقویت گرادیان شدید به‌عنوان روش‌های مقایسه‌ای انتخاب شد. عملکرد این مدل‌ها با استفاده از اعتبارسنجی متقاطع و بر اساس داده‌های سالانه در یک دوره پنج‌ساله بررسی گردید. در این فرایند، داده‌های هر سال به‌عنوان یک بلوک زمانی مستقل در نظر گرفته شد. جدول ۳ نتایج پیش‌بینی روش پیشنهادی را در مقایسه با مدل‌های پایه در دوره‌های خارج از نمونه نمایش می‌دهد.

جدول ۳. عملکرد پیش‌بینی روش پیشنهادی در مقایسه با روش‌های معیار

XGBoost-GA (Genetic Algorithm)		XGBoost (Simple)		SVM (Support Vector Machine)		Random Forest		Logistic Regression		Folds of Cross-validation	
F1-score	Accuracy	F1-score	Accuracy	F1-score	Accuracy	F1-score	Accuracy	F1-score	Accuracy		
۰/۷۱	۰/۷۱	۰/۵۸	۰/۷۲	۰/۶۹	۰/۷۷	۰/۵۷	۰/۷۳	۰/۵۸	۰/۶۵	۹۹-۹۸	۱
۰/۹۱	۰/۹۲	۰/۶۳	۰/۶۸	۰/۶۹	۰/۷۳	۰/۵۲	۰/۶۳	۰/۳۴	۰/۵۵	۴۰۰-۹۹	۲
۰/۹۳	۰/۹۳	۰/۵۶	۰/۶۳	۰/۵۲	۰/۶۴	۰/۴۸	۰/۶۳	۰/۱۴	۰/۵۴	۴۰۱-۴۰۰	۳
۰/۸۰	۰/۷۹	۰/۶۶	۰/۵۶	۰/۳۴	۰/۵۳	۰/۶۸	۰/۵۶	۰/۲۸	۰/۵۱	۴۰۲-۴۰۱	۴
۰/۸۲	۰/۸۴	۰/۵۵	۰/۵۸	۰/۴۹	۰/۶۲	۰/۴۹	۰/۵۲	۰/۵۹	۰/۵۴	۴۰۳-۴۰۲	۵
۰/۸۴	۰/۸۴	۰/۶۰	۰/۶۳	۰/۵۵	۰/۶۶	۰/۵۵	۰/۶۱	۰/۳۹	۰/۵۶	Average of model	
۰/۰۲۸	۰/۰۳۴۴	۰/۰۱۸	۰/۰۸۳۲	۰/۰۵۷	۰/۰۴۹۶	۰/۰۱۶	۰/۰۹۳۶	۰/۰۹۳	۰/۰۳۵۲	Bias	
۰/۰۱۲	۰/۰۲۷	۰/۰۰۳	۰/۰۱۴	۰/۰۷۱	۰/۰۹۵	۰/۰۰۲	۰/۰۲۵	۰/۰۸۲	۰/۰۰۸	Variance	

نتایج حاصل از اجرای مدل‌ها نشان می‌دهد که روش پیشنهادی در هر دو معیار دقت و امتیاز F1، عملکرد بهتری نسبت به سایر مدل‌ها داشته است. میانگین دقت مدل پیشنهادی (ترکیب الگوریتم تقویت گرادیان شدید با بهینه‌سازی ژنتیک) برابر با ۸۴ درصد بود، در حالی که مدل‌های دیگر مانند رگرسیون لجستیک ۵۶ درصد، جنگل تصادفی ۶۱ درصد، ماشین بردار پشتیبان ۶۶ درصد و نسخه ساده الگوریتم تقویت گرادیان ۶۰ درصد دقت داشتند. همچنین امتیاز F1 مدل پیشنهادی نیز ۸۴ درصد به‌دست آمد، در حالی که این مقدار برای سایر مدل‌ها به‌ترتیب ۳۹، ۵۵، ۵۵ و ۶۳ درصد گزارش شد.

این نتایج نشان می‌دهد که مدل پیشنهادی هم در دقت و هم در شناسایی روندها عملکرد برتری دارد. علاوه‌براین، ارزیابی متقاطع زمانی با واریانس و بایاس بسیار پایین، تعمیم‌پذیری مدل در دوره‌های مختلف بازار را تأیید می‌کند. همچنین برای بررسی معناداری تفاوت عملکرد مدل‌ها، از آزمون فریدمن استفاده شد (مطابق با جدول ۳).

جدول ۴. نتایج آزمون فریدمن برای بررسی معناداری تفاوت میان ارزیابی عملکرد روش پیشنهادی با روش‌های معیار

F1-score testing results	Accuracy testing results	مدل‌های مقایسه‌شده
Significant level $\alpha = 0.05$	Significant level $\alpha = 0.05$	
$H_0: n_1 = n_2 = n_3 = n_4 = n_5$	$H_0: n_1 = n_2 = n_3 = n_4 = n_5$	LR vs XGB-GA
F_Statistics = ۱۱/۷۵	F_Statistics = ۱۴/۴۸	RF vs XGB-GA
P_Value < ۰/۰۵ (reject H_0)	P_Value < ۰/۰۵ (reject H_0)	SVM vs XGB-GA
		XGB-S vs XGB-GA

بر اساس جدول ۴، مقدار آماره آزمون فریدمن برای معیار دقت برابر با ۱۴/۴۸ و امتیاز F1 برابر با ۱۱/۷۵ به دست آمد. با توجه به مقدار احتمال کمتر از ۰/۰۵، فرضیه صفر مبنی بر برابری عملکرد مدل‌ها رد شد. این نتیجه بیانگر آن است که تفاوت عملکرد میان مدل‌ها معنادار است و برتری مدل پیشنهادی صرفاً ناشی از تصادف یا ویژگی‌های خاص داده‌ها نیست. بهینه‌سازی پارامترهای الگوریتم تقویت‌گرا دیان شدید با استفاده از الگوریتم ژنتیک، به‌طور معناداری موجب بهبود دقت و کارایی مدل در پیش‌بینی تغییرات جهت شاخص کل بورس تهران شده است. در نتیجه، فرضیه پژوهش تأیید می‌شود.

جدول ۵ نتایج استراتژی معاملات شبیه‌سازی‌شده روش پیشنهادی و روش‌های پایه دوره‌های خارج از نمونه با در نظر گرفتن محدودیت فروش استقراضی در معاملات نمایش می‌دهد.

جدول ۵. نتایج استراتژی معاملات شبیه‌سازی‌شده روش پیشنهادی و روش‌های پایه

Buy & Hold	XGBoost-GA	XGBoost	SVM	RF	LR	Folds of Cross-validation	
۴۴۷/۱۲	۴۶۷/۵۹	۴۶۲/۳۸	۴۵۶/۸۲	۴۵۵/۶۵	۴۱۰/۳۲	۹۹-۹۸	۱
۱۲/۴۳	۱۷/۳۴	۱۶/۴۵	۱۵/۶۲	۱۴/۶۳	۱۳/۱۲	۴۰۰-۹۹	۲
-۴/۱۰	۳/۲	-۰/۰۲	-۲/۹۸	-۴/۲۱	-۷/۲۸	۴۰۱-۴۰۰	۳
۵۲/۸۲	۶۲/۴۵	۵۶/۵۶	۵۳/۰۳	۵۲/۶۳	۵۱/۷۳	۴۰۲-۴۰۱	۴
۱/۱۴	۴/۰۹	۲/۰۸	۲/۴۵	۱/۶۵	۰/۰۱	۴۰۳-۴۰۲	۵
۴۶۰/۹۴	۱۰۵۱/۲۱	۹۱۶/۹۶	۸۷۲/۱۸	۸۳۸/۴۷	۷۲۷/۵۳	سود مرکب تجمیعی	

به‌منظور سنجش اثرگذاری عملی پیش‌بینی‌ها، شبیه‌سازی یک استراتژی سرمایه‌گذاری بر اساس سیگنال‌های تولیدشده توسط مدل XGBoost-GA اجرا شد. در این استراتژی فرضی، هر زمان که مدل جهت صعودی شاخص را پیش‌بینی می‌کرد، ورود به بازار (خرید دارایی) انجام می‌شد و در سایر زمان‌ها خروج یا حفظ نقدینگی در نظر گرفته می‌شد. بازده حاصل از این استراتژی با استراتژی پایه نگهداری و فروش (Buy & Hold) مقایسه شد.

نتایج جدول ۵ نشان داد که استراتژی مبتنی بر مدل یادگیری ماشین بازده بالاتری نسبت به استراتژی نگهداری و فروش ارائه داده است؛ به‌ویژه در دوره‌هایی که بازار رفتار نوسانی یا نزولی داشته، استفاده از سیگنال‌های مدل توانسته

افت سرمایه را کاهش دهد. این تحلیل نشان می‌دهد که دقت مدل تنها به معنای پیش‌بینی آماری نبوده، بلکه قابلیت ترجمه به تصمیمات مالی مؤثر را نیز دارد.

در تنظیمات الگوریتم ژنتیک، تعداد نسل‌ها^۱ برابر با ۵ انتخاب شده است تا فرایند تکامل در طی پنج مرحله به سمت بهبود عملکرد مدل هدایت شود. اندازه جمعیت اولیه^۲ برابر ۵۰ در نظر گرفته شده است تا تنوع کافی در کروموزوم‌ها وجود داشته باشد و الگوریتم از گرفتار شدن در بهینه‌های محلی، جلوگیری کند. مقدار حالت تصادفی^۳ برابر با ۴۲ تنظیم شده است تا امکان بازتولیدپذیری نتایج فراهم شود. میزان نمایش جزئیات خروجی^۴ نیز بر روی مقدار ۲ تنظیم شده است. این فرایند در قالب کلاس TPOTRegressor در پایتون پیاده‌سازی شده است. همچنین هایپرپارامترهای مدل‌های تقویت‌گرایان شدید پژوهش نیز در جدول ۶ قابل مشاهده است.

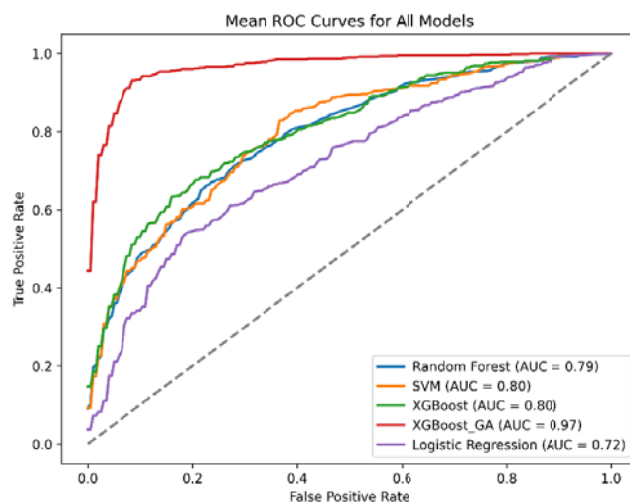
جدول ۶. مقادیر هایپرپارامترهای بهینه‌شده توسط الگوریتم ژنتیک در مدل‌های تقویت‌گرایان شدید

Model	n_estimators	max_depth	Learning_rate	subsample	Colsample_bytree
XGBoost	۱۰۰	۶	۰/۳۰	۱	۱
XGBoost-GA	۳۵۰	۵	۰/۰۳	۰/۷۰	۰/۸۰

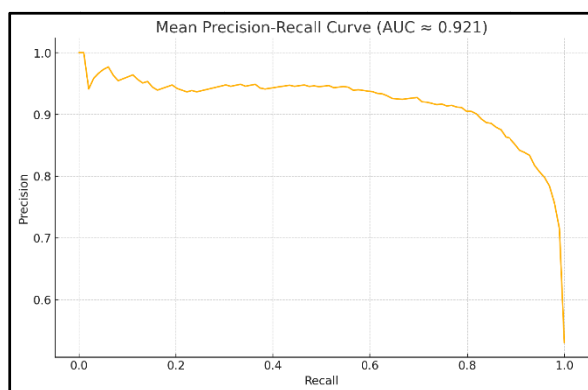
شکل ۱ منحنی مشخصه عملکرد سیستم (ROC)^۵ را برای مدل‌های مختلف پیش‌بینی «جهت شاخص کل» بورس اوراق بهادار تهران نشان می‌دهد. محور افقی، نرخ مثبت کاذب^۶ و محور عمودی، نرخ مثبت واقعی^۷ را نشان می‌دهد. هرچه منحنی یک مدل به گوشه بالا - چپ نزدیک‌تر باشد، آن مدل در تفکیک صحیح کلاس‌ها (پیش‌بینی جهت شاخص) عملکرد بهتری دارد.

بررسی منحنی‌ها نشان می‌دهد که مدل پیشنهادی با مقدار سطح زیر منحنی (AUC) برابر با ۰/۹۷، نسبت به سایر مدل‌ها عملکرد بسیار برتری دارد و قادر است به‌خوبی روندهای افزایشی و کاهش‌ی شاخص متمایز کند. در مقابل، ماشین بردار پشتیبان و نسخه ساده الگوریتم تقویت‌گرایان، هر دو با AUC برابر با ۰/۸۰، عملکردی مشابه ولی ضعیف‌تر ارائه دادند. جنگل تصادفی با AUC برابر با ۰/۷۹ و رگرسیون لجستیک با ۰/۷۲ نیز عملکرد پایین‌تری داشتند. این نتایج نشان می‌دهد که بهینه‌سازی پارامترهای مدل پیشنهادی با استفاده از الگوریتم ژنتیک، به‌طور معناداری دقت و کارایی پیش‌بینی آن را در مقایسه با سایر روش‌ها افزایش داده است.

1. generations
2. population_size
3. random state
4. verbosity
5. Mean Receiver Operating Characteristic (ROC) Curve
6. False Positive Rate
7. True Positive Rate



شکل ۱. منحنی میانگین مشخصه عملکرد سیستم برای مدل‌های مختلف پیش‌بینی جهت شاخص کل بورس اوراق بهادار تهران



شکل ۲. منحنی میانگین Precision-Recall برای مدل پیشنهادی XGBoost-GA

به‌منظور ارزیابی دقیق‌تر عملکرد مدل پیشنهادی در شرایط عدم توازن داده‌ها، منحنی میانگین دقت - بازیابی^۱ نیز ترسیم شده است. همان‌طور که در شکل ۲ مشاهده می‌شود، مدل در طیف گسترده‌ای از مقادیر بازیابی، توانسته است سطح بالایی از دقت را حفظ کند.

مقدار سطح زیر منحنی (AUC) برابر با ۰/۹۲۱ به‌دست آمده است که بیانگر کارایی بالای مدل در شناسایی صحیح کلاس مثبت (یعنی پیش‌بینی روند صعودی شاخص) و در عین حال، کاهش نرخ پیش‌بینی‌های نادرست مثبت است. این عملکرد مطلوب نشان می‌دهد که دقت بالای مدل ناشی از بیش‌برازش نیست، بلکه نتیجه‌ی بهینه‌سازی دقیق پارامترهای مدل و بهره‌گیری از سازوکارهای کنترل پیچیدگی مانند منظم‌سازی^۲ و اعتبارسنجی متقاطع سری‌زمانی است.

1. Precision-Recall
2. Regularization

۲. کارایی ضعیف، نیمه‌قوی و بازدهی مدل ترکیبی: آیا استفاده از اطلاعات گذشته شاخص کل بورس (کارایی ضعیف) و ترکیب اطلاعات بنیادی و تکنیکال (کارایی نیمه‌قوی) در یک مدل یادگیری ماشینی، می‌تواند بازدهی بیشتری نسبت به یک مدل پیش‌بینی تصادفی یا مدل‌های مبتنی بر تنها شاخص‌های تکنیکال ارائه دهد؟ جهت تحلیل سؤال ۲، نتایج حاصل از تحلیل کارایی بازار در دو سطح ضعیف و نیمه‌قوی ارائه می‌شود. مقایسه عملکرد مدل‌های مختلف در پیش‌بینی جهت شاخص کل بورس اوراق بهادار تهران، بستری مناسب برای ارزیابی میزان کارایی بازار در سطوح مذکور فراهم می‌سازد.

- **کارایی بازار در سطح نیمه‌قوی:** به‌منظور ارزیابی کارایی نیمه‌قوی، مدل پیشنهادی در دو پیکربندی مورد بررسی قرار گرفت: نخست، مدل با استفاده منحصراً از متغیرهای تکنیکال آموزش داده شد و سپس، با افزودن ویژگی‌های بنیادی به مجموعه ورودی، عملکرد مدل ارزیابی شد. نتایج نشان داد که مدل ترکیبی که از هر دو دسته ویژگی‌های بنیادی و تکنیکال بهره می‌برد، دقت بیشتری در پیش‌بینی جهت شاخص داشته است (دقت: ۰/۸۴، امتیاز F1: ۰/۸۴) بهبود معنادار عملکرد مدل پس از افزودن اطلاعات بنیادی، دلالت بر ناکارایی بازار در سطح نیمه‌قوی دارد؛ زیرا در یک بازار نیمه‌قوی کارا، اطلاعات بنیادی نباید تأثیر معناداری بر پیش‌بینی‌پذیری قیمت‌ها داشته باشد.

- **کارایی بازار در سطح ضعیف:** در راستای ارزیابی کارایی ضعیف، عملکرد مدل مبتنی بر ویژگی‌های تکنیکال (XGBoost-GA با متغیرهای تکنیکال) با عملکرد مدل گام تصادفی مقایسه شد. نتایج نشان داد که مدل تکنیکال عملکرد بهتری نسبت به مدل گام تصادفی ارائه می‌دهد. این یافته نشان‌دهنده آن است که اطلاعات تکنیکال حاوی الگوهایی است که می‌توانند در پیش‌بینی جهت شاخص مورد استفاده قرار گیرند. در یک بازار کارای ضعیف، قیمت‌های گذشته و الگوهای تکنیکال نباید قابلیت پیش‌بینی داشته باشند؛ بنابراین، برتری مدل تکنیکال نسبت به مدل تصادفی، ناکارایی بازار در سطح ضعیف را تأیید می‌کند.

جدول ۷ عملکرد پیش‌بینی روش پیشنهادی با تغییر در ورودی‌های مدل را در مقایسه با روش پیش‌بینی تصادفی

برای دوره‌های خارج از نمونه، نشان می‌دهد.

جدول ۷. عملکرد پیش‌بینی روش پیشنهادی در مقایسه با روش پیش‌بینی تصادفی

XGBoost-GA(**) (Technical and Fundamental Indicator)		XGBoost-GA (*) (Technical Indicator)		Random Walk Model		Folds of Cross-validation	
F1-score	Accuracy	F1-score	Accuracy	F1-score	Accuracy		
۰/۷۱	۰/۷۱	۰/۵۹	۰/۵۶	۰/۵۱	۰/۵۵	۹۹-۹۸	۱
۰/۹۱	۰/۹۲	۰/۶۷	۰/۶۰	۰/۶۰	۰/۵۶	۴۰۰-۹۹	۲
۰/۹۳	۰/۹۳	۰/۵۹	۰/۵۸	۰/۵۶	۰/۵۴	۴۰۱-۴۰۰	۳
۰/۸۰	۰/۷۹	۰/۵۱	۰/۵۲	۰/۴۸	۰/۴۸	۴۰۲-۴۰۱	۴
۰/۸۲	۰/۸۴	۰/۴۵	۰/۵۸	۰/۴۲	۰/۴۶	۴۰۳-۴۰۲	۵
۰/۸۴	۰/۸۴	۰/۵۶	۰/۵۷	۰/۵۱	۰/۵۲	Average of model	


سپس، مطابق با جدول ۸ برای بررسی معناداری این تفاوت‌ها، آزمون فریدمن اجرا شد.

جدول ۸. نتایج آزمون فریدمن برای بررسی معناداری تفاوت میان ارزیابی عملکرد روش پیشنهادی با روش‌های معیار

F1-score testing results Significant level $\alpha = 0.05$	Accuracy testing results Significant level $\alpha = 0.05$	مدل‌های مقایسه‌شده
$H_0: n_1 = n_2 = n_3$	$H_0: n_1 = n_2 = n_3$	Random Walk
$F_Statistics = ۸/۴۱$	$F_Statistics = ۱۰/۰۰$	vs XGB-GA (*)
$P_Value < ۰/۰۵$ (reject H_0)	$P_Value < ۰/۰۵$ (reject H_0)	vs XGB-GA (**)

آزمون فریدمن نیز تفاوت معنادار در عملکرد مدل‌ها را تأیید می‌کند ($P\text{-value} > ۰/۰۵$)، که نشان‌دهنده معنادار بودن آماری تفاوت‌های مشاهده‌شده بین مدل‌ها است. این تحلیل به وضوح نشان می‌دهد که بازار سرمایه ایران در هر دو سطح ضعیف و نیمه‌قوی ناکارا است و اطلاعات قیمتی گذشته و داده‌های بنیادی می‌توانند برای پیش‌بینی جهت شاخص مورد استفاده قرار گیرند.

شکل ۳، نمودار ROC ارائه شده، مقایسه‌ای بصری از عملکرد سه مدل در پیش‌بینی «جهت شاخص کل» بورس اوراق بهادار تهران ارائه می‌دهد. مدل تصادفی ($AUC = ۰/۵۰$) عملکردی مشابه با حدس تصادفی دارد که با شرایط یک بازار کارای ضعیف همخوانی دارد. مدل GA_only technical ($AUC = ۰/۶۰$) عملکرد بهتری از خود نشان می‌دهد که تأیید می‌کند اطلاعات تکنیکال در پیش‌بینی شاخص مؤثر است و بازار در سطح ضعیف ناکارا است. در نهایت، مدل XGBoost-GA ($AUC = ۰/۹۲$) با بهره‌گیری از متغیرهای تکنیکال و بنیادی، بهترین عملکرد را داشته است که نشان‌دهنده تأثیر معنادار اطلاعات بنیادی و تأیید ناکارایی بازار در سطح نیمه‌قوی است.



شکل ۳. منحنی میانگین مشخصه عملکرد سیستم برای مقایسه پیش‌بینی جهت شاخص کل بورس اوراق بهادار تهران در حالت‌های مختلف کارایی بازار

در مجموع، یافته‌های مربوط به سؤال دوم نشان می‌دهند که بازار سرمایه ایران در هر دو سطح ضعیف و نیمه‌قوی ناکارا است.

۳. اهمیت متغیرها در سناریوهای مختلف کارایی: در دو سناریوی عدم وجود کارایی ضعیف و نیمه‌قوی، رتبه‌بندی اهمیت و تأثیر متغیرهای تکنیکال و بنیادی در مدل یادگیری ماشینی چگونه است؟


برای درک نحوه تأثیرگذاری متغیرهای ورودی بر پیش‌بینی مدل، از نمودار خلاصه شاپ^۱ بهره گرفته شده است. این نمودار به صورت بصری میزان و جهت تأثیر ویژگی‌های مختلف بر خروجی مدل را نمایش می‌دهد. هر نقطه در نمودار نمایانگر یک مشاهده در مجموعه داده‌هاست و ظرفیت رنگ نقاط، بیانگر مقدار ویژگی مربوطه می‌باشد. تحلیل این نمودار به صورت زیر است (لاندرگ و همکاران، ۲۰۲۰):

- مقادیر مثبت در نمودار شاپ (نقاط قرمزتر) به ویژگی‌هایی اشاره دارند که موجب افزایش مقدار پیش‌بینی شده توسط مدل می‌شوند. به بیان دیگر، افزایش مقادیر این ویژگی‌ها معمولاً منجر به بالا رفتن دقت در خروجی مدل خواهد شد.
 - مقادیر منفی (نقاط آبی‌تر) به ویژگی‌هایی تعلق دارند که باعث کاهش مقدار پیش‌بینی شده می‌شوند. این متغیرها تأثیر معکوسی بر دقت مدل دارند.
 - محور افقی، مقادیر شاپ را نمایش می‌دهد؛ به طوری که مقدار مطلق بالاتر بدین معناست که آن ویژگی تأثیر بیشتری بر مدل دارد.
 - محور عمودی، ترتیب اهمیت کلی ویژگی‌ها را از بالا به پایین نمایش می‌دهد، به طوری که ویژگی‌های قرار گرفته در بالاترین نقاط، بیشترین تأثیر را بر پیش‌بینی‌های مدل دارند.
- این تحلیل به اهمیت نقش متغیرهای ورودی در مدل کمک کرده و نشان می‌دهد کدام ویژگی‌ها برای پیش‌بینی جهت حرکت شاخص کل اهمیت بیشتری دارند.

در مدل تکنیکال مطابق با شکل ۴ که صرفاً از شاخص‌های تکنیکی استفاده می‌کند، نتایج زیر به دست آمده است:

- شاخص قدرت نسبی ۱۴ روزه (RSI_14): این شاخص در صدر متغیرهای تأثیرگذار قرار دارد و نشان‌دهنده این است که شتاب حرکتی بازار در بازه‌های زمانی کوتاه‌مدت نقش به‌سزایی در پیش‌بینی جهت شاخص دارد. مقدار بالای RSI معمولاً به معنی خرید افراطی و مقدار پایین آن نمایانگر فروش افراطی است.
- حجم معاملات (TrVol): تأثیر بالا و معنادار این متغیر نشان می‌دهد که تغییرات در حجم معاملات می‌تواند سیگنال‌های مهمی برای پیش‌بینی جهت شاخص ارائه دهد. افزایش ناگهانی حجم معاملات اغلب به‌عنوان نشانه‌ای از تغییر روند بازار تلقی می‌شود.

- انحراف معیار ۱۴ روزه (SD_14): این شاخص به عنوان معیاری از نوسانات کوتاه مدت، نقش مهمی در شناسایی رفتار بازار ایفا می کند. نوسان های بالا معمولاً به افزایش عدم قطعیت در بازار مرتبط است.
- MACD و MACD_Signal: این شاخص ها برای بررسی واگرایی و همگرایی میانگین های متحرک مورد استفاده قرار می گیرند و قدرت روندهای صعودی یا نزولی را نشان می دهند. موقعیت این شاخص ها در نمودار SHAP، اهمیت آن ها را در پیش بینی جهت شاخص برجسته می سازد.




شکل ۴. قابلیت تفسیر مدل با استفاده از مقادیر SHAP با در نظر گرفتن شاخص های تکنیکال

در مدل ترکیبی مطابق با شکل ۵ که شامل متغیرهای بنیادی، تکنیکال و کلان اقتصادی است، نتایج به دست آمده متفاوت است:

- ورود خالص پول حقیقی (NFin): این متغیر در مدل ترکیبی به عنوان مهم ترین عامل شناسایی شده و بیانگر اهمیت بالای جریان نقدینگی حقیقی در بازار است. ورود سرمایه گذاران حقیقی معمولاً با افزایش تقاضا و رشد قیمت ها مرتبط می شود.
- ورود خالص پول حقوقی (NCIn): این عامل نمایان گر جریان نقدینگی شرکت های حقوقی است. تأثیر بالای این متغیر نشان دهنده تأثیر جدی رفتار سرمایه گذاران بزرگ و نهادی بر جهت دهی به بازار است.

- قیمت صندوق طلای لوتوس (LTF-Price): اهمیت این متغیر حاکی از ارتباط میان بازار طلا و بازار سهام است، به‌ویژه در شرایط بی‌ثباتی اقتصادی که تمایل سرمایه‌گذاران به سمت دارایی‌های امن مانند طلا افزایش می‌یابد.



شکل ۵. قابلیت تفسیر مدل با استفاده از مقادیر SHAP با در نظر گرفتن شاخص‌های تکنیکال و بنیادی

- سایر متغیرهای مربوط به سودآوری بازار و شرکت‌ها در درجه دوم اهمیت قرار دارند. از جمله:
- بازده دارایی‌ها و بازده حقوق صاحبان سهام (RoE و RoA): این شاخص‌ها نمایانگر سودآوری شرکت‌ها هستند. تأثیر معنادار این متغیرها در مدل ترکیبی نمایانگر اهمیت بالای عملکرد مالی شرکت‌ها در پیش‌بینی جهت شاخص است.
 - بازده لگاریتمی شاخص کل بورس اوراق بهادار تهران (Index): این متغیر نیز در هر دو مدل جزو عوامل تأثیرگذار است و تدوین آن نقش روند کلی بازار را در پیش‌بینی جهت شاخص تأیید می‌کند.
 - TrVol و MACD: این دو متغیر تکنیکال هنوز هم در مدل ترکیبی تأثیرگذارند که این امر بیانگر پایداری نقش اطلاعات تکنیکال حتی در حضور داده‌های بنیادی است.

نتایج این تحلیل‌ها نشان می‌دهد که ترکیب ویژگی‌های بنیادی و تکنیکال در مدل به‌طور معناداری بر دقت پیش‌بینی‌ها تأثیرگذار است و می‌تواند به‌عنوان ابزاری مؤثر در تصمیم‌گیری‌های سرمایه‌گذاری مورد استفاده قرار گیرد. بنابراین، نتایج این بخش، تصویری روشن از توانایی مدل پیشنهادی در پیش‌بینی بازار، نقش اطلاعات بنیادی و تکنیکال و نیز میزان کارایی بازار بورس تهران ارائه داد.

بحث و نتیجه‌گیری

این پژوهش به‌عنوان نخستین مطالعه در ایران، به بررسی قابلیت توضیح‌پذیری هوش مصنوعی در پیش‌بینی شاخص‌های مالی پرداخته است که گامی نو در به‌کارگیری مدل‌های یادگیری ماشین در بازار سرمایه محسوب می‌شود. برخلاف مطالعات پیشین که صرفاً بر دقت پیش‌بینی تمرکز داشتند، این پژوهش با ترکیب الگوریتم تقویت‌گرایان شدید، بهینه‌سازی پارامترها با الگوریتم ژنتیک و روش‌های توضیح‌پذیری، تلاش کرده است تا هم‌زمان به دقت بالا و تفسیرپذیری مدل‌ها دست یابد و در راستای توسعه نظریه کارایی بازار حرکت کند.

یافته‌های این تحقیق با مطالعات بین‌المللی معتبر هم‌راستا هستند. برای مثال، پژوهش چن و همکاران (۲۰۲۲) نشان داد که مدل‌های مبتنی بر یادگیری ماشین، از جمله تقویت‌گرایان شدید، به‌دلیل توانایی بالا در مدل‌سازی روابط پیچیده، عملکرد بهتری نسبت به مدل‌های سنتی اقتصادسنجی دارند. علاوه‌براین، لوندبرگ و لی (۲۰۱۷) بر اهمیت استفاده از روش‌های توضیح‌پذیری از جمله شاپ تأکید کردند و نشان دادند که چنین مدل‌هایی نه تنها دقت پیش‌بینی را افزایش می‌دهند، بلکه اعتماد سرمایه‌گذاران و سیاست‌گذاران را نیز جلب می‌کنند. این نتایج با چارچوب نظری و تجربی پژوهش حاضر هم‌خوانی دارد؛ زیرا مدل پیشنهادی ما نشان داد که با افزایش شفافیت مدل، تحلیلگران مالی قادر خواهند بود تصمیمات آگاهانه‌تری اتخاذ کنند. بررسی متغیرهای ورودی نشان داد که عوامل رفتاری سهام‌داران حقیقی و حقوقی، نظیر ورود و خروج پول به بازار و همچنین بازده بازارهای موازی مانند طلا، تأثیر بیشتری نسبت به متغیرهای کلان اقتصادی همچون نرخ بهره بر دقت پیش‌بینی دارند. این یافته‌ها با تحقیقات بین‌المللی که به اهمیت متغیرهای بنیادی و رفتاری در پیش‌بینی بازده بازارهای مالی اشاره دارند، هم‌راستا است. در این راستا، رفتار قیمتی و اندیکاتورهای نظیر بازده لگاریتمی شاخص، میانگین متحرک نمایی، شاخص MACD و حجم معاملات به‌عنوان مهم‌ترین متغیرهای مؤثر تکنیکال شناسایی شدند.

مدل پیشنهادی از پایداری و تعمیم‌پذیری بالایی برخوردار است و برخلاف بسیاری از مدل‌ها، در طول زمان دچار افت عملکرد نمی‌شود. این مدل علاوه‌بر دقت بالا، با قابلیت توضیح‌پذیری خود، ابزاری مؤثر برای تحلیل‌گران در تصمیم‌گیری‌های مالی، مدیریت ریسک و بهینه‌سازی سبد دارایی به‌شمار می‌آید.

یکی از محدودیت‌های اصلی پژوهش، دسترسی نداشتن به داده‌های کامل قیمتی سهام بود؛ تنها قیمت پایانی در تحلیل‌ها استفاده شد که دقت برخی اندیکاتورهای تکنیکال را کاهش داد. البته تحلیل حساسیت نشان داد که جایگزینی قیمت پایانی با میانگین روزانه، به افت دقت و F1 در حدود ۲ تا ۳ درصد و کاهش AUC کمتر از ۱ درصد منجر شد. این

نتایج بیانگر پایداری مدل در برابر حذف داده‌های OHLC و نقش غالب قیمت پایانی در انتقال سیگنال پیش‌بینی است. در نتیجه، محدودیت داده‌های قیمتی روزانه تأثیر معناداری بر عملکرد عملی مدل ندارد.

همچنین به دلیل ممنوعیت فروش استقراری در بازار ایران، امکان ارزیابی سودآوری در روندهای نزولی وجود نداشت و تحلیل‌ها صرفاً بر روندهای صعودی متمرکز بودند. برای رفع این محدودیت‌ها، پیشنهاد می‌شود در آینده از داده‌ها و سازوکارهای بازار آپشن استفاده شود؛ چرا که هم اطلاعات قیمتی دقیق‌تری ارائه می‌دهد و هم امکان طراحی استراتژی‌های معاملاتی در شرایط متنوع بازار را فراهم می‌سازد.

با توجه به یافته‌های این پژوهش، مسیرهای متعدد دیگری برای تحقیقات آینده وجود دارد که می‌توانند به بهبود مدل‌های پیش‌بینی بازارهای مالی و افزایش شفافیت در فرایندهای تصمیم‌گیری کمک کنند. یکی از حیاتی‌ترین حوزه‌های پیشنهادی، توسعه مدل‌هایی است که از تحلیل اخبار برای بررسی روندهای روزانه بازار سهام بهره می‌برند. در این راستا، می‌توان با ادغام روش‌های پردازش زبان طبیعی (NLP) و یادگیری عمیق، تأثیر اخبار اقتصادی، سیاسی و مالی را بر رفتار سهام تجزیه و تحلیل کرده و مدل‌های پیش‌بینی را بر اساس این داده‌های متنی بهبود بخشید. علاوه بر این، پژوهش در مورد تأثیر عوامل کلان اقتصادی بر نوسان‌های بازار، به‌ویژه در شرایط خاصی مانند تحریم‌های اقتصادی، می‌تواند به‌عنوان حوزه‌ای ارزشمند برای تحقیقات آینده در نظر گرفته شود. با افزودن متغیرهایی مانند میزان فروش نفت ایران و درآمدهای ارزی کشور به مدل‌های تحلیلی، می‌توان تأثیر سیاست‌های کلان اقتصادی را بر روندهای بلندمدت بازار سهام ارزیابی کرد. این رویکرد به درک بهتر رابطه میان شرایط اقتصادی و نوسان‌های بازار کمک خواهد کرد. تحلیل دقیق تأثیر نرخ تورم بر دقت پیش‌بینی و رفتار متغیرهای بنیادی به‌عنوان یک مسیر پیشنهادی برای تحقیقات آینده معرفی شده است. پیشنهاد می‌شود در مطالعات آتی از متغیرهای تعدیل‌شده با نرخ تورم یا شاخص‌های تورم‌زدایی‌شده برای بهبود کیفیت تحلیل استفاده شود.

از دیگر سو، توسعه مدل‌های توضیح‌پذیر در حوزه مالی نیز اهمیت بالایی دارد. در این پژوهش، تمرکز بیشتر بر روی توضیح‌پذیری مدل‌های هوش مصنوعی در بازار سهام بوده است؛ اما باید توجه ویژه‌ای به بازار پول نیز معطوف شود. به‌عنوان مثال، استفاده از مدل‌های توضیح‌پذیر در مدیریت ریسک اعتباری می‌تواند به بانک‌ها و مؤسسات مالی در بهبود فرایندهای تصمیم‌گیری و کاهش ریسک نکول یاری دهد. در حوزه نظارت بر بازار سرمایه، نهادهای نظارتی مانند سازمان بورس می‌توانند از تکنیک‌های توضیح‌پذیری محلی نظیر LIME در بهبود سیستم‌های شناسایی دست‌کاری در بازار سهام استفاده کنند. این تکنیک‌ها می‌توانند با افزایش شفافیت فرایندهای نظارتی و دقت در شناسایی رفتارهای مشکوک، سطح اعتماد سرمایه‌گذاران را به بازار مالی ارتقا دهند.

در نهایت، تحقیقات آینده در این حوزه‌ها هم می‌توانند به بهبود دقت مدل‌های پیش‌بینی کمک کند و هم موجب افزایش کارایی در سیستم‌های مالی و نظارتی شوند و در نهایت، به ایجاد بازاری کارآمدتر، شفاف‌تر و قابل پیش‌بینی‌تر منجر شوند. از این رو، توسعه مدل‌ها و روش‌های نوین، در کنار استفاده از تکنیک‌های پیشرفته یادگیری ماشین و هوش مصنوعی، می‌تواند به ایجاد تحولاتی مهم در بازارهای پولی و مالی کمک شایانی کند.

منابع

- حیدری، مهدی و امیری، حمیدرضا (۱۴۰۱). بررسی قدرت مدل‌های مبتنی بر هوش مصنوعی در پیش‌بینی روند قیمت سهام بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۴(۴)، ۶۰۲-۶۲۳.
- ذوقی، سهیل؛ راعی، رضا و فلاح‌پور، سعید (۱۴۰۱). ارائه مدل پیش‌بینی گر جهت بازار در معاملات آتی سکه طلای بورس کالای ایران با استفاده از الگوریتم حافظه طولانی کوتاه مدت (LSTM). *مهندسی مالی و مدیریت اوراق بهادار*، ۵۳(۱۳)، ۳۴-۵۳.
- راعی، رضا؛ وحدتی، مسعود؛ محبی، حسین و حیدری دلویی، امیرحسین (۱۴۰۳). تفسیر پیش‌بینی بازده شاخص قیمت صنایع تولیدی بورس اوراق بهادار تهران با استفاده از یادگیری تجمیعی توضیح‌پذیر. *چشم‌انداز مدیریت مالی*، ۱۴(۴۸)، ۷۸-۵۵.
- سهرابی، مریم؛ میربرگ‌کار، سیدمظفر؛ چیرانی، ابراهیم و خریدار، سینا (۱۴۰۲). مقایسه مدل‌های مختلف یادگیری ماشین در پیش‌بینی شاخص بازار سهام. *مهندسی مالی و مدیریت اوراق بهادار*، ۵۶(۱۴)، ۱۹-۳۶.
- عباسی، ابراهیم؛ محمدی مقدم، فاطمه و قالیباف اصل، حسن (۱۴۰۳). ارتباط بین اهرم مالی با عملکرد مالی با تأکید بر درماندگی مالی و بحران ارزی در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۶(۴)، ۸۸۰-۹۰۳.

References

- Abbasi, E., Mohammadimoghadam, F. & Ghalibafasl, H. (2024). The Relationship between Financial Leverage and Financial Performance: Emphasizing Financial Distress and Currency Crisis in the Tehran Stock Exchange. *Financial Research Journal*, 26(4), 880-903. (in Persian)
- Athey, S. & Imbens, G. W. (2019). Machine learning methods economists should know about. *Annual Review of Economics*, 11, 685-725.
- Athey, S. & Imbens, G. W. (2021). The econometrics of randomized experiments. *Annual Review of Economics*, 13, 451-483.
- Bergmeir, C., Hyndman, R. J. & Benitez, J. M. (2023). Cross-validation for time series: A systematic review. *Expert Systems with Applications*, 220, 119567.
- Berrar, D. (2019). *Cross-validation*.
- Bussmann, N., Giudici, P., Marinelli, D. & Papenbrock, J. (2021). Explainable machine learning in credit risk management. *Computational Economics*, 57, 203-216.
- Cao, Y., Gedikli, F. & Vrancx, P. (2024). Advances and challenges in financial time series forecasting with machine learning. *Artificial Intelligence in Finance*, 100088.
- Chen, T. & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. In *proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*. 785-794.
- Chollet, F. (2021). *Deep learning with Python* (2nd ed.). Manning Publications.

- Deng, S., Huang, X., Zhu, Y., Su, Z., Fu, Z. & Shimada, T. (2023). Stock index direction forecasting using an explainable eXtreme Gradient Boosting and investor sentiments. *The North American Journal of Economics and Finance*, 64, 101848.
- Dimitriadou, A., Gogas, P., Papadimitriou, T. & Plakandaras, V. (2018). Oil market efficiency under a machine learning perspective. *Forecasting*, 1(1), 157-168.
- Etsalakis, A. & Valavanis, G. (2009). Predicting financial indices using neural networks: Nonlinear machine learning models outperform traditional approaches. *Journal of Financial Forecasting and Machine Learning*, 5(2), 112–130.
- Fama, E. F. & French, K. R. (2020). Comparing cross-section and time-series factor models. *The Review of Financial Studies*, 33(5), 1891–1926.
- Gu, S., Kelly, B. & Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5), 2223-2273.
- Hassan, M. K., Rahman, M. M. & Kim, S. (2023). Evaluating classification performance in stock trend prediction: A comparative analysis of confusion matrix metrics. *Expert Systems with Applications*, 215, 119231.
- Heidari, M. & Amiri, H. (2022). Inspecting the Predictive Power of Artificial Intelligence Models in Predicting the Stock Price Trend in Tehran Stock Exchange. *Financial Research Journal*, 24(4), 602-623. (in Persian)
- Li, S. & Zhang, X. (2019). Research on orthopedic auxiliary classification and prediction model based on XGBoost algorithm. *Neural Computing and Applications*, 32, 1971–1979.
- Lo, A. W. & MacKinlay, A. C. (1988). Stock market prices do not follow random walks: Evidence from a simple specification test. *The Review of Financial Studies*, 1(1), 41–66.
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., ... & Lee, S.-I. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2(1), 56-67.
- Mohebbi, H. & Zare Mehrjardi, A. (2019). Investigating the Effect of Proactive market Orientation on Creating Market Changes and its Consequences in the tile and ceramic industry. *Commercial Surveys*, 17(98), 98-113.
- Molnar, C. (2025). *Interpretable machine learning: A guide for making black box models explainable* (3rd ed.).
- Raei, R., Vahdati, M., Mohebbi, H. & Heydari Delooei, A. (2025). Interpreting Forecast the Return of the Price Index of Manufacturing Industries in the Tehran Stock Exchange Using Explainable Ensemble Learning. *Financial Management Perspective*, 14(48), 55-78. (in Persian)
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206-215.
- Shobayo, O., Adeyemi-Longe, S., Popoola, O. & Okoyeigbo, O. (2025). A Comparative Analysis of Machine Learning and Deep Learning Techniques for Accurate Market Price Forecasting. *Analytics*, 4(1), 5.

- Sivanandam, S. N. & Deepa, S. N. (2008). *Introduction to genetic algorithms*. Springer.
- Smith, J., Johnson, R. & Lee, H. (2023). Enhancing model robustness in financial market predictions through cross-validation techniques. *Journal of Financial Data Science*, 15(2), 45–60.
- Sohrabi, M., Mirberg Kar, S. M., Chirani, E. & Kherdiar, S. (2023). Comparison of different machine learning models in predicting stock market indices. *Financial Engineering and Securities Management Journal*, 14(56), 19–36. (in Persian)
- Štrumbelj, E., & Kononenko, I. (2014). Explaining prediction models and individual predictions with feature contributions. *Knowledge and information systems*, 41(3), 647-665.
- Thaler, R. H. (2016). Behavioral economics: Past, present, and future. *American Economic Review*, 106(7), 1577–1600.
- Yang, C., Abedin, M. Z., Zhang, H., Weng, F. & Hajek, P. (2025). An interpretable system for predicting the impact of COVID-19 government interventions on stock market sectors. *Annals of Operations Research*, 347(2), 1031-1058.
- Yuan, X., Yuan, J., Jiang, T. & Ain, Q. U. (2020). Integrated long-term stock selection models based on feature selection and machine learning algorithms for China stock market. *IEEE Access*, 8, 22672- 22685.
- Zhang, Y., Li, X. & Wang, J. (2024). Deep learning and market efficiency: Evidence from high-frequency trading. *Journal of Financial Economics*, 151(3), 102–125.
- Zhong, X. & Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, 5(1), 4.
- Zoghi, S., Raei, R. & Falahpor, S. (2022). Presenting a market direction prediction model for gold coin trades in Iran's Commodity Exchange market using Long Short-Term Memory (LSTM) algorithm. *Financial Engineering and Portfolio Management*, 13(53), 34-53. (in Persian)