



Predicting Mutual Fund Returns in Member Countries of the Federation of Euro-Asian Stock Exchanges: A Spatial and Artificial Intelligence Approach

Nashmil Esmaily

PhD Candidate, Department of Accounting, Faculty of Economics and Management, Urmia University, Urmia, Iran. E-mail: nashmilesma1370@gmail.com

Parviz Piri *

*Corresponding Author, Associate Prof., Department of Accounting, Faculty of Economics and Management, Urmia University, Urmia, Iran. E-mail: p.piri@urmia.ac.ir

Ali Ashtab

Assistant Prof., Department of Accounting, Faculty of Economics and Management, Urmia University, Urmia, Iran. E-mail: a.ashtab@urmia.ac.ir

Mehdi Heydari

Associate Prof., Department of Accounting, Faculty of Economics and Management, Urmia University, Urmia, Iran. E-mail: m.heydari@urmia.ac.ir

Akbar Zavarirezaei

Assistant Prof., Department of Accounting, Faculty of Economics and Management, Urmia University, Urmia, Iran. E-mail: a.zavarirezaei@urmia.ac.ir

Abstract

Objective

The primary objective of this study is to forecast the returns of investment funds in developed and developing countries that are members of the Federation of Euro-Asian Stock Exchanges (FEAS).

Methods

This applied research study analyzes financial data from investment funds in FEAS countries over the period 2015–2023. The modeling framework employs artificial intelligence

Citation: Esmaily, Nashmil; Piri, Parviz; Ashtab, Ali; Heydari, Mehdi & Zavarirezaei, Akbar (2026). Predicting Mutual Fund Returns in Member Countries of the Federation of Euro-Asian Stock Exchanges: A Spatial and Artificial Intelligence Approach. *Financial Research Journal*, 28(1), 187-235. <https://doi.org/10.22059/FRJ.2025.385026.1007665> (in Persian)



techniques, spatial econometrics, and a hybrid approach combining both within a spatial hybrid panel structure. The study examines the effects of key variables—including the Sharpe ratio, Jensen's alpha, asset growth rate, and the proportion of retail investors—on fund returns. The central aim is to assess the predictive efficiency of these models under different economic conditions.

Results

The findings demonstrate that artificial intelligence models outperform alternative approaches in forecasting returns for both developed and developing country groups. The neoclassical neural network showed the strongest performance across both groups, while the multilayer perceptron also proved effective in developed markets; in contrast, decision tree models exhibited weaker predictive capability. Moreover, integrating artificial intelligence methods with spatial techniques led to significant improvements in forecasting accuracy. The results indicate that market returns had a positive effect in both groups, with a more pronounced impact in developed countries. The analysis identified the Sharpe ratio, Jensen's alpha, asset growth rate, and the proportion of retail investors as significant determinants of fund returns. Notably, the Sharpe ratio had a significant positive effect in both groups, reflecting the greater sensitivity of investors in developed markets to risk-adjusted returns. Finally, forecasting mutual fund returns using the combined artificial intelligence and spatial hybrid panel approach revealed substantial differences in model performance between developed and developing countries. In developed countries, models such as the multilayer perceptron and decision tree achieved superior performance, whereas in developing countries, deep learning and support vector machine models demonstrated greater effectiveness.

Conclusion

This study demonstrates that developed markets substantially outperform developing markets in terms of predictability and performance stability. Advanced artificial intelligence models proved effective in forecasting fund returns in both developed and developing country groups. Ultimately, the design of hybrid models that integrate artificial intelligence with spatial analysis and spatial hybrid panels can enhance the accuracy of fund return forecasts, thereby enabling investors and fund managers to make more informed financial decisions. Accordingly, the implementation of hybrid artificial intelligence and spatial hybrid panel models in both groups improved efficiency and increased forecasting precision, exerting a considerable influence on the quality of financial decision-making. This research also revealed that variables affecting fund returns—including the Sharpe ratio, Jensen's alpha, asset growth rate, and the proportion of retail investors—together with countries' economic conditions, influence model performance, underscoring the importance of incorporating macroeconomic factors into financial and accounting analyses. For market practitioners and financial analysts, these findings can contribute to enhanced financial reporting processes, more rigorous risk assessment, and improved investment decision-making. Specifically, the results can facilitate greater transparency of financial information within investment funds.

Keywords: Return forecasting, Spatial approach, Mutual fund, Member countries of the Federation of Euro-Asian Stock Exchanges (FEAS), Artificial intelligence.

پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی - رویکرد فضایی و هوش مصنوعی

نشمیل اسماعیلی

دانشجوی دکتری، گروه حسابداری مالی، دانشکده اقتصاد و مدیریت، دانشگاه ارومیه، ارومیه، ایران. رایانامه: nashmilesma1370@gmail.com

پرویز پیری*

* نویسنده مسئول، دانشیار، گروه حسابداری، دانشکده اقتصاد و مدیریت، دانشگاه ارومیه، ارومیه، ایران. رایانامه: p.piri@urmia.ac.ir

علی آشتاب

استادیار، گروه حسابداری، دانشکده اقتصاد و مدیریت، دانشگاه ارومیه، ارومیه، ایران. رایانامه: a.ashtab@urmia.ac.ir

مهدی حیدری

دانشیار، گروه حسابداری، دانشکده اقتصاد و مدیریت، دانشگاه ارومیه، ارومیه، ایران. رایانامه: m.heydari@urmia.ac.ir

اکبر زواری رضایی

استادیار، گروه حسابداری، دانشکده اقتصاد و مدیریت، دانشگاه ارومیه، ارومیه، ایران. رایانامه: a.zavarirezai@urmia.ac.ir

چکیده

هدف: هدف اصلی این مقاله، پیش‌بینی بازده صندوق‌های سرمایه‌گذاری در کشورهای توسعه‌یافته و در حال توسعه فدراسیون بورس‌های اروپایی و آسیایی است.

روش: پژوهش حاضر از نوع کاربردی است و داده‌های مالی دوره ۲۰۱۵ تا ۲۰۲۳ مرتبط با صندوق‌های کشورهای توسعه‌یافته و در حال توسعه را بررسی می‌کند. برای مدل‌سازی، روش‌های هوش مصنوعی، اقتصادسنجی فضایی و ترکیب این دو در چارچوب پانل هیبرید فضایی به کار رفته‌اند تا تأثیر متغیرهای مهمی همچون نسبت شارپ، معیار بازدهی تفاضلی جنسن، رشد ارزش و درصد سرمایه‌گذاران حقیقی بر بازده بررسی شود. هدف اصلی، سنجش کارایی مدل‌ها در پیش‌بینی عملکرد صندوق‌ها تحت شرایط اقتصادی متفاوت است.

یافته‌ها: نتایج نشان می‌دهد که مدل‌های هوش مصنوعی نسبت به سایر روش‌ها، توانایی بیشتری برای پیش‌بینی بازده هر دو گروه کشورهای توسعه‌یافته و در حال توسعه دارند. شبکه عصبی نئوکلاسیک، بهترین عملکرد را در هر دو گروه نشان داده است، در حالی که

استناد: اسماعیلی، نشمیل؛ پیری، پرویز؛ آشتاب، علی؛ حیدری، مهدی و زواری رضایی، اکبر (۱۴۰۵). پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی - رویکرد فضایی و هوش مصنوعی. *تحقیقات مالی*، ۲۸(۱)، ۱۸۷-۲۳۵.

پرسپترون چند لایه در کشورهای توسعه‌یافته نیز موفق بوده و درخت تصمیم ضعیف‌تر ظاهر شده است. همچنین، ترکیب روش‌های هوش مصنوعی با تکنیک‌های فضایی، باعث افزایش معنادار دقت پیش‌بینی شده است. یافته‌ها حاکی از آن است که بازده بازار در هر دو گروه اثر مثبت دارد و در کشورهای توسعه‌یافته پررنگ‌تر است. تحلیل‌های انجام شده نشان داد که متغیرهای مؤثر بر بازده صندوق‌ها، شامل نسبت شارپ، معیار بازدهی تفاضلی جنسن، رشد ارزش و درصد سرمایه‌گذاران حقیقی بوده‌اند. نسبت شارپ در هر دو گروه، تأثیر مثبت معناداری داشته است و حساسیت بالای سرمایه‌گذاران در بازارهای توسعه‌یافته به ریسک تعدیل شده بازده را نشان می‌دهد. در نهایت، نتایج پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک با استفاده از رویکرد ترکیبی هوش مصنوعی و پانل هیبرید فضایی، نشان می‌دهد که عملکرد مدل‌ها در کشورهای توسعه‌یافته و در حال توسعه، تفاوت‌های معناداری دارد. در کشورهای توسعه‌یافته، مدل‌هایی مانند پرسپترون چند لایه و درخت تصمیم، بهترین عملکرد را داشته‌اند، در حالی که در کشورهای در حال توسعه، یادگیری عمیق و ماشین بردار پشتیبان برتری نشان داده‌اند.

نتیجه‌گیری: پژوهش حاضر نشان داد که بازارهای توسعه‌یافته از نظر پیش‌بینی‌پذیری و ثبات عملکرد، به مراتب بهتر از بازارهای در حال توسعه هستند. همچنین مدل‌های پیشرفته هوش مصنوعی در پیش‌بینی بازده صندوق‌ها، در هر دو گروه کشورهای توسعه‌یافته و در حال توسعه کارایی دارند. در نهایت، طراحی مدل‌های ترکیبی از هوش مصنوعی و تحلیل‌های فضایی و پانل هیبرید فضایی، می‌تواند دقت پیش‌بینی بازده صندوق‌ها را بهبود بخشد و به سرمایه‌گذاران و مدیران صندوق‌ها در اتخاذ تصمیم‌های مالی مؤثرتر کمک کند. بنابراین، طراحی مدل‌های ترکیبی هوش مصنوعی و پانل هیبرید فضایی، در هر دو گروه، باعث بهبود کارایی و افزایش دقت پیش‌بینی شده است و قادر است بر کیفیت تصمیم‌گیری‌های مالی تأثیر بسزایی بگذارد. این پژوهش نشان داد که متغیرهای مؤثر بر بازده صندوق‌ها، شامل نسبت شارپ، معیار بازدهی تفاضلی جنسن، رشد ارزش و درصد سرمایه‌گذاران حقیقی و شرایط اقتصادی کشورها، بر عملکرد این مدل‌ها تأثیر می‌گذارد. این امر اهمیت در نظر گرفتن عوامل کلان اقتصادی در تحلیل‌های مالی و حسابداری را برجسته می‌کند. برای فعالان بازار و تحلیلگران مالی، این نتایج می‌تواند به بهبود فرایندهای گزارشگری مالی، ارزیابی ریسک، و تصمیم‌گیری‌های سرمایه‌گذاری منجر شود. یافته‌های این پژوهش، به صورت ویژه می‌تواند به گسترش دامنه اطلاعات مالی صندوق‌های سرمایه‌گذاری کمک کند.

کلیدواژه‌ها: پیش‌بینی بازده، رویکرد فضایی، صندوق سرمایه‌گذاری مشترک، کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی، هوش مصنوعی.

مقدمه

سرمایه‌گذاری از مباحث کلیدی در اقتصاد تمامی کشورهاست که برای افراد حقیقی و مقامات دولتی، اهمیت زیادی دارد. این فرایند شامل انتخاب دارایی‌هایی است که به‌منظور حفظ و کسب عایدی بیشتر انجام می‌شود تا رفاه بیشتری برای سرمایه‌گذار فراهم شود. سرمایه‌گذاران همواره در جست‌وجوی روش‌هایی برای کسب درآمد در آینده هستند و پیش از هرگونه اقدام سرمایه‌گذاری، دو معیار اصلی را مد نظر قرار می‌دهند: نخست، سرمایه‌گذاری باید یکی از سه بازده بالقوه حداکثری را به همراه داشته باشد و دوم، این بازده باید ثابت و مداوم باشد. از این رو، بازده سهام به‌عنوان یکی از معیارهای اساسی در فرایند تصمیم‌گیری در بازار بورس به‌شمار می‌رود (اخباری، محمدزاده سالطه، برادران حسن‌زاده و زینالی، ۱۴۰۳).

ثروت سهام‌داران به دو عامل ریسک و بازده بستگی دارد. تعیین بازده آتی به‌طور دقیق امکان‌پذیر نیست؛ بنابراین سهام‌داران هنگام سرمایه‌گذاری ریسک را می‌پذیرند و برای حداکثر کردن منافع خویش، به‌دنبال پیش‌بینی بازده سهام هستند. از طرفی، مهم‌ترین عامل مدنظر سرمایه‌گذاران بازده سهام است. از این رو، سرمایه‌گذاران در بازار سرمایه، می‌کوشند تا پس‌اندازهای خود را در سرمایه‌گذاری‌هایی صرف کنند که بیشترین بازدهی را داشته باشد. برای دستیابی به این هدف، آن‌ها نیاز به اطلاعاتی دارند تا بتوانند بازده یک سرمایه‌گذاری را پیش‌بینی کنند (چنگ و هولیو^۱، ۲۰۰۸). پیش‌بینی‌پذیری بازده بازار سهام برای سال‌ها مورد توجه آکادمیک و پژوهشگران بوده است (فرشادفر و پروکوپچوک^۲، ۲۰۱۹).

تحقیقات تاریخی نشان داده است که افزایش توانایی پیش‌بینی، به کاهش ریسک سرمایه‌گذاری منجر می‌شود؛ تحقیق در زمینه پیش‌بینی بازار مالی، برای سرمایه‌گذاران خصوصی و نهادی اهمیت زیادی دارد. همچنین، پیش‌بینی بازده پرتفوی برای هیئت‌رئیس شرکت‌ها نیز بسیار مهم است؛ زیرا این پیش‌بینی به روشن شدن اهداف و استراتژی‌های آن‌ها در زمینه ارزش‌گذاری شرکت‌ها کمک می‌کند (فن، شارما و نارایان^۳، ۲۰۱۵). با افزایش پیچیدگی فرایندهای مدیریت سرمایه‌گذاری، وظیفه دستیابی به این اهداف، به مدیران سرمایه‌گذاری حرفه‌ای واگذار شده و این امر، به پیدایش تعدادی سرمایه‌گذاری مانند صندوق‌های سرمایه‌گذاری مشترک منجر شده است (پاتل، گوپتا و مادهاون^۴، ۲۰۲۳). صندوق‌های سرمایه‌گذاری، مؤسسه‌های مالی‌ای هستند که هدف آن‌ها جمع‌آوری وجوه از سرمایه‌گذاران جدید و واگذاری آن به خرید اوراق بهادار به‌منظور کاهش ریسک سرمایه‌گذاری است. این صندوق‌ها از جمله مؤسسه‌های مالی رابطی دارند که باعث می‌شود سرمایه‌گذاران غیرحرفه‌ای، بازارهای حرفه‌ای داشته باشند (ترابی، طریقی و تاتایی^۵، ۲۰۱۶).

1. Cheng and Hollio
2. Farshadfar & Prokopczuk
3. Phan, Sharma & Narayan
4. Patel, Gupta & Madhavan
5. Torabi, Tarighi & Tataei

سرمایه‌گذاری در صندوق‌های مشترک در بازارهای مالی جهان، به‌ویژه در اقتصادهای در حال توسعه، نقش حیاتی ایفا می‌کند (کاناد، شردیوالا و شرکار^۱، ۲۰۲۲)؛ زیرا این صندوق‌ها وسیله‌ای برای مدیریت ریسک سرمایه‌گذاران محسوب می‌شود و می‌تواند با جمع‌آوری منابع، آن‌ها را به سمت یک سبد متنوع هدایت کنند. کاهش ریسک از طریق تنوع که به‌وسیله این ابزار ممکن می‌شود، به سرمایه‌گذاران این امکان را می‌دهد که خود را از نوسان‌های بازار محافظت کنند، در حالی که مدیریت متخصص توسط مدیران باتجربه صندوق به آن‌ها کمک می‌کند تا با تصمیم‌گیری‌های پهنه‌تر به بازدهی بالاتری دست یابند. علاوه‌براین، راحتی نقدینگی روزانه که سرمایه‌گذاران را قادر به خرید یا فروش به‌صورت روزانه می‌کند، این نوع سرمایه‌گذاری را برای کسانی که به‌دنبال دسترسی سریع به دارایی‌های خود هستند، جذاب‌تر می‌سازد. در نتیجه، انتخاب صندوق‌های سرمایه‌گذاری مشترک، به‌عنوان یک گزینه جذاب برای افرادی که به‌دنبال سرمایه‌گذاری بر بازدهی متنوع و بهره‌مندی از تخصص مدیریت حرفه‌ای صندوق هستند، مطرح می‌شود (بون پراسوی و تپایا وانگ^۲، ۲۰۲۴). همچنین صندوق‌های سرمایه‌گذاری بازده مطمئن ارائه نمی‌کنند بلکه بازده آن‌ها به عملکرد آن‌ها مرتبط است و نوسان‌های بازده صندوق می‌تواند ریسک صندوق را اندازه‌گیری کند (شو، سلیمان و یئونگ^۳، ۲۰۱۲).

در برخی مطالعات نشان داده شده است که تغییرات در نوسان‌ها در طول زمان با تغییرات متناسب در بازده مورد انتظار خنثی نمی‌شود (ژنگ، ژنگ، لین و یو^۴، ۲۰۲۴). صندوق‌های سرمایه‌گذاری از نظر چگونگی سرمایه‌گذاری در آن‌ها به دو دسته تقسیم می‌شوند. دسته اول مبتنی بر صدور و ابطال و دسته دوم صندوق‌های قابل معامله^۵ هستند. صندوق‌های قابل معامله در بورس که در سال ۱۹۹۳ معرفی شدند، امروزه به یکی از نوآوری‌های بسیار جالب و با ارزش در صنعت مالی تبدیل شده‌اند (نیوکوران^۶، ۲۰۲۰). اکثر صندوق‌های قابل معامله یک شاخص یا بخش خاص را دنبال می‌کنند و می‌توانند در بورس اوراق بهادار معامله شوند. صندوق‌های قابل معامله، نسبتاً هزینه‌های کمتری را متحمل می‌شوند و برای بهره‌وری مالیاتی ساختار یافته‌اند و آن‌ها را نسبت به صندوق‌های سرمایه‌گذاری، برای پیروی از یک استراتژی سرمایه‌گذاری غیرفعال جذاب‌تر می‌کند (بن دیوید، فرنزونی و موسوی^۷، ۲۰۱۷). میفرا^۸ (۲۰۰۷) بیان کرده است که مزایای تنوع بین‌المللی را می‌توان با صندوق‌های قابل معامله کشور به دلیل ریسک متنوع، هزینه کم، خطای ردیابی کم و کارایی بهتر هنگام ثبت مالیات روی آن‌ها به‌دست آورد. دو ارزش با یک صندوق‌های قابل معامله مرتبط است، ارزش خالص دارایی و ارزش بازار صندوق‌های قابل معامله. موضوع مهم در رابطه با این نوع سرمایه‌گذاری، پیش‌بینی بازده مورد انتظار سرمایه‌گذاری در صندوق‌های قابل معامله است.

1. Kanade, Sherdiwala & Shrekar
2. Boonprasope & Tippayawong
3. Shu, Sulaeman & Yeung
4. Zhang, Zheng, Lien & Yu
5. Exchange-traded fund (ETF)
6. Nyukorong
7. Ben – David, Franzoni & Moussawi
8. Miffre

از آنجایی که اثربخشی انتخاب سرمایه‌گذاری به شدت به عملکرد آتی بازار سهام وابسته است. پیش‌بینی‌های معقول و دقیق، احتمالاً به بازده سرمایه‌گذاری خوب و همچنین کاهش ریسک منجر می‌شود و همچنین، پیش‌بینی بازار سهام یک پیش‌بینی دشوار است؛ زیرا به‌طور کلی، بازار سهام یک سیستم غیرخطی پویا است. علاوه بر این، قیمت سهام تحت تأثیر عوامل مختلفی قرار می‌گیرد. این عوامل شامل رویدادهای سیاسی، سیاست‌ها و اطلاعیه‌های شرکت‌ها، وضعیت اقتصادی، نرخ بهره و احساسات سرمایه‌گذاران هستند.

همچنین، تحقیقات نشان می‌دهند که روش‌های هوش مصنوعی و یادگیری ماشین می‌توانند به پیش‌بینی قیمت‌ها کمک کنند. مطالعات مقایسه‌ای نشان داده‌اند که یادگیری ماشین در حل مسائل غیرخطی و پیش‌بینی ناپذیر بهتر از مدل‌های آماری عمل می‌کند (توکلی و آشتاب، ۱۴۰۲)؛ بنابراین با در نظر گرفتن اهمیت پیش‌بینی بازده در این نوع سرمایه‌گذاری‌ها، این مقاله به بررسی روش‌های یادگیری ماشین برای تخمین بازده مورد انتظار صندوق‌های قابل معامله پرداخته است. به علاوه، بازده پرتفوی‌های صندوق‌های سرمایه‌گذاری کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی را پیش‌بینی و همچنین با استفاده از این تکنیک‌ها، بازده کشورهای عضو فدراسیون مربوطه را با در نظر گرفتن فرض کشورهای توسعه‌یافته و در حال توسعه (سینگانیا و ساینی^۱، ۲۰۲۳؛ قریشی، کوتان، غفور، خان و قریشی^۲، ۲۰۱۹؛ دانقاه و یو^۳، ۲۰۲۳) مقایسه می‌کند.

با توجه به مطالب فوق، پژوهش حاضر به بررسی پیش‌بینی بازده پرتفوی‌های صندوق‌های سرمایه‌گذاری در کشورهای توسعه‌یافته و در حال توسعه عضو فدراسیون بورس‌های اروپایی و آسیایی با استفاده از رویکردهای یادگیری ماشین پرداخته است. همچنین، این تحقیق به مقایسه نتایج پیش‌بینی در این دو دسته کشور می‌پردازد و هدف آن، ارائه بینشی بهتر در زمینه پیش‌بینی بازده و شناسایی الگوهای برتر است. این اطلاعات به فعالان و متخصصان در زمینه تشکیل سبد سرمایه‌گذاری از بازارهای بین‌المللی کمک می‌کند تا تصمیمات اقتصادی بهتری اتخاذ کنند. در نهایت، هدف این مطالعه، مقایسه بازده صندوق‌های قابل معامله در بورس کشورهای توسعه‌یافته و در حال توسعه از طریق استفاده از رویکردهای هوش مصنوعی است. در ادامه، پس از تحلیل ادبیات و مرور پیشینه تحقیق، به تشریح روش‌شناسی پرداخته و سپس یافته‌ها ارائه و نتیجه‌گیری و پیشنهادها بیان می‌شود.

ادبیات و پیشینه پژوهش

بسیاری معتقدند که پیش‌بینی بازده صندوق، ابزاری مؤثر برای مدیریت ریسک و تنوع پرتفوی است. عواملی چون شرایط اقتصادی، رویدادهای بین‌المللی و رفتار انسانی بر تحرکات بازار تأثیر می‌گذارند، پس پیش‌بینی بازده کاری چالش‌برانگیز است. سودآوری سرمایه‌گذاری در بازار، به توانایی پیش‌بینی حرکت سهام بستگی دارد و اگر مدل یا تکنیک پیش‌بینی

1. Singhanian & Saini
2. Qureshi, Kutan, Ghafoor, Khan & Qureshi
3. Danquah & Yu

دقیقی وجود داشته باشد، می‌توان ریسک و عدم اطمینان را به حداقل رساند (ملکارجونو و راو^۱، ۲۰۱۹)؛ بنابراین برای پیش‌بینی حرکت قیمت سهام، دو روش اصلی وجود دارد: تحلیل بنیادی و تحلیل تکنیکال که به‌عنوان دو مکتب فکری متمایز شناخته می‌شود. در تحلیل بنیادی، قیمت سهام بر اساس بررسی‌های مالی شرکت‌ها یا صنایع پیش‌بینی می‌شود. تحلیلگران تکنیکال از داده‌های تاریخی معاملات استفاده می‌کنند و با این فرض که نیروهای بازار قیمت سهام را مشخص می‌کنند، قیمت‌های آتی را پیش‌بینی می‌کنند (لوی^۲، ۱۹۶۷).

این نظریه‌ها برای چندین دهه به‌عنوان استراتژی‌هایی برای تصمیم‌گیری سرمایه‌گذاری وجود داشتند. این رویکردها در دهه ۱۹۶۰ توسط تئوری گام تصادفی که عموماً به‌عنوان فرضیه بازار کارآمد شناخته می‌شود، به چالش کشیده شد (فاما^۳، ۱۹۷۰) که پیشنهاد می‌کند تغییرات آتی در قیمت سهام را نمی‌توان از تغییرات قیمت گذشته پیش‌بینی کرد. با این حال، بیشتر مطالعات تجربی نشان داده‌اند که قیمت سهام قابل پیش‌بینی است (هریسون و مور^۴، ۲۰۱۲؛ چن، ما، کیو و لی^۵، ۲۰۲۳). تکنیک‌های مختلف پیش‌بینی برای پیش‌بینی سری‌های زمانی، مانند مدل‌های میانگین متحرک یکپارچه خود رگرسیون توسط باکس و پیرس^۶ (۱۹۷۰) برای تحلیل سری‌های زمانی و پیش‌بینی پیشنهاد شده‌اند. علاوه‌براین، مدل‌های شبکه عصبی مختلفی برای پیش‌بینی بازده سهام وجود دارد. نمازی و کیامهر (۱۳۸۶) به این نتیجه رسیده‌اند که شبکه‌های عصبی مصنوعی توانایی پیش‌بینی بازده را با خطای نسبتاً کمی دارند. همچنین ژونگ و انکه^۷ (۲۰۱۹) مشاهده کردند که تکنیک‌هایی مانند شبکه‌های عصبی عمیق با استفاده از تحلیل مؤلفه‌های اصلی و شبکه‌های عصبی مصنوعی، بهتر از مدل‌های سنتی عمل می‌کنند.

برخی از محققان از روش‌های یادگیری ماشین برای تجزیه و تحلیل و پیش‌بینی بازده صندوق‌های سرمایه‌گذاری استفاده کرده‌اند و نتایج به‌ویژه در زمینه ریسک و بازده، برتری مدل‌های یادگیری ماشین را در مقایسه با پیش‌بینی‌های ساده و استراتژی‌های سنتی سرمایه‌گذاری نشان می‌دهد (پیووزان، دی آندرید جونیور و آوالیا^۸، ۲۰۲۲).

با وجود تکنیک‌های متعدد برای پیش‌بینی بازده بازار سهام، هیچ روش واحدی برای همه بازارها به‌طور یکسان کارایی ندارد. محققان نیز در مورد بهترین تکنیک‌ها برای پیش‌بینی بازده بازار سهام توافق ندارند. به همین دلیل، شناسایی روش‌های کارآمد برای پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک می‌تواند به بهبود عملکرد این صندوق‌ها کمک کند. با توجه به رشد روزافزون این نوع سرمایه‌گذاری‌ها، پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک اهمیت زیادی دارد؛ بنابراین در این خصوص مطالعات متعددی وجود دارد که در ادامه به بخشی از مهم‌ترین آن‌ها نیز اشاره می‌شود که به شرح جدول ۱ است.

1. Mallikarjuna & Rao
2. Levy
3. Fama
4. Harrison & Moore
5. Chen, Ma, Qiu & Li
6. Box & Pierce
7. Zhong & Enke
8. Piovezan, de Andrade Junior & Ávila

جدول ۱. پیشینه پژوهش‌های داخلی و خارجی

نویسندگان	بازه زمانی	هدف	نتیجه
بالی، بروان و کاگلایان ^۱ (۲۰۱۴)		هدف مقاله مذکور بررسی تأثیر ریسک‌های کلان اقتصادی و عدم قطعیت اقتصادی بر برقراری و بازدهی صندوق‌های پوشش ریسک ^۲ و صندوق‌های سرمایه‌گذاری مشترک ^۳ است.	نتایج نشان داد که رابطه مثبت بین بتاهای عدم قطعیت و بازده‌های آتی صندوق‌های پوشش ریسک از لحاظ اقتصادی و آماری معنادار است، در حالی که این رابطه در صندوق‌های سرمایه‌گذاری مشترک معنادار نیست. این تحقیق همچنین نشان می‌دهد که مدیران صندوق‌های پوشش ریسک با توانایی زمان‌بندی مناسب، می‌توانند با افزایش یا کاهش سطح ریسک کلان اقتصادی در پرتفوی‌های خود، به نوسان‌های اقتصادی به خوبی پاسخ دهند. بنابراین، این تحقیق به اهمیت ریسک‌های کلان اقتصادی به‌عنوان عاملی مهم در تعیین تفاوت‌های مقطعی در بازده‌های صندوق‌های پوشش ریسک تأکید می‌کند.
جوزف، لارین و ترنر ^۴ (۲۰۱۷)	۲۰۱۶-۲۰۰۳	هدف پژوهش، بررسی ویژگی‌ها و قابلیت پیش‌بینی بازده‌های روزانه سهام است. این مطالعه به تحلیل خصوصیات بازدهی روزانه سهام، همچنین رابطه میان آن‌ها و عوامل اقتصادی مؤثر بر قیمت‌های سهام می‌پردازد.	این مطالعه به بررسی قابلیت پیش‌بینی بازده سهام با نرخ بهره معکوس پرداخت. معیارهای دقت پیش‌بینی مورد استفاده، ریشه میانگین مربعات خطا و هم‌بستگی بود. پیش‌بینی‌ها در همه موارد به‌عنوان مثال با مدل‌های شبکه عصبی امکان‌پذیر بوده است.
آبه و ناکایاما ^۵ (۲۰۱۸)	۲۰۱۶-۱۹۹۰	هدف تحقیق، به‌کارگیری یادگیری عمیق برای پیش‌بینی بازده سهام در یک ماه آینده در مقیاس مقطعی بازار سهام ژاپن و بررسی عملکرد این روش است.	نتایج تحقیق نشان داد که شبکه‌های عصبی عمیق به‌طور کلی عملکرد بهتری نسبت به شبکه‌های عصبی سطحی دارند و بهترین شبکه‌ها نیز عملکرد بهتری نسبت به مدل‌های نماینده یادگیری ماشین دارند. این نتایج نشان‌دهنده این است که یادگیری عمیق به‌عنوان یک روش کارآمد در یادگیری ماشین برای پیش‌بینی بازده سهام در مقیاس مقطعی نشان‌دهنده پتانسیل خوبی است.

1. Bali, Brown & Caglayan
2. hedge funds
3. mutual funds
4. Joseph, Larrain & Turner
5. Abe & Nakayama

نویسندگان	بازه زمانی	هدف	نتیجه
مالیکارچونا و راتو (۲۰۱۹)	۲۰۱۸-۲۰۰۰	در مقاله مذکور به بررسی عملکرد پیش‌بینی مدل‌های خطی، غیرخطی، هوش مصنوعی، دامنه فرکانسی و ترکیبی به‌منظور یافتن یک مدل مناسب برای پیش‌بینی بازده سهام در بازارهای توسعه‌یافته، نوظهور و مرزی پرداخته شده است.	نتایج نشان داد که هیچ مدل واحدی از پنج مدل را نمی‌توان به‌طور یکسان در همه بازارها اعمال کرد. با این حال، مدل‌های خطی و غیرخطی سنتی در ارائه پیش‌بینی‌های دقیق از هوش مصنوعی و مدل‌های حوزه فرکانس بهتر عمل کردند.
یو، چوی، لی و لین ^۱ (۲۰۲۰)	۲۰۱۹-۲۰۰۴	هدف از این تحقیق، پیش‌برد مدل‌های پرتفوی از طریق گنجاندن پیش‌بینی بازده و تحلیل دقیق‌تر عملکرد واقعی آن‌ها است. این تحقیق بر آن است که با در نظر گرفتن هزینه‌های معاملاتی و بهینه‌سازی وزن‌های فروش کوتاه‌مدت در زمینه توازن پرتفوی، عملی بودن مدل‌ها را تضمین کند.	مدل‌های یادگیری ماشینی بدون فرضیه‌های محدود، عملکرد بهتری نسبت به مدل ARIMA نشان داده‌اند.
ما، هان و ونگ ^۲ (۲۰۲۱)	۲۰۱۵-۲۰۰۷	هدف از این تحقیق، ادغام پیش‌بینی بازده مدل‌های سری زمانی سنتی با مدل‌های یادگیری ماشین و یادگیری عمیق است	نتایج تجربی پژوهش نشان داد که مدل‌های میانگین واریانس و امگا با پیش‌بینی بازده جنگل تصادفی، یعنی RF+MVF و RF+OF، از مدل‌های دیگر بهتر عمل می‌کنند.
هاروی و لیو ^۳ (۲۰۲۲)	۲۰۲۲	هدف از این پژوهش، جدا کردن شانس از مهارت در ارزیابی عملکرد صندوق با استفاده از تکنیک بوت استرپینگ ^۴ است.	یک چارچوب جدید راه‌اندازی کرده است که این امکان را می‌دهد نرخ خطای نوع یک (ادعای نادرست عملکرد بهتر یک صندوق) و همچنین قدرت (احتمال شناسایی یک صندوق واقعاً با عملکرد بهتر) را بررسی کرد. در طراحی شبیه‌سازی، این پژوهش دقیقاً نشان می‌دهد که کدام صندوق‌ها عملکرد بهتری دارند و این امکان را فراهم می‌کند که این نرخ‌های خطا را اندازه‌گیری کنیم.
فیبرگ، متکو، پوددگ و لوی ^۵ (۲۰۲۳)	۲۰۱۹-۱۹۹۰	هدف بررسی تکنیک‌های یادگیری ماشین برای پیش‌بینی بازده سهام است.	نتایج پژوهش نشان داد که پیش‌بینی بازده سهام را می‌توان به‌طور قطعی از طریق روش‌های یادگیری ماشینی بهبود بخشید.

1. Yu, Chiou, Lee & Lin

2. Ma, Han & Wang

3. Harvey & Liu

4. Bootstrapping

5. Fieberg, Metko, Poddig & Loy

نویسندگان	بازه زمانی	هدف	نتیجه
پیووزان و جونیور ^۱ (۲۰۲۳)	۲۰۲۲-۲۰۱۲	آنان پیشنهاد به کارگیری یک روش یادگیری ماشین برای تحلیل جهت بازدهی صندوق‌های قابل معامله با استفاده از داده‌های بازده تاریخی اجزای ارائه دادند که به اتخاذ تصمیمات استراتژیک سرمایه‌گذاری از طریق یک الگوریتم معاملاتی کمک می‌کند.	نتایج تحقیق، نشان داد که پیش‌بینی ساده و بازده به‌دست‌آمده از تکنیک خرید و نگهداری در همان بازه زمانی، از نظر ریسک و بازده، مدل‌ها عمدتاً با تأکید بر مدل رگرسیون خطی و مدل‌های طبقه‌بندی با استفاده از رگرسیون لجستیک، ماشین بردار پشتیبان، بیز ساده گوسی و نزدیکترین همسایه‌ها، بهتر از معیارهای کنترل عمل کردند، جایی که در مجموعه داده‌های خاص بازدهی دو برابر و نسبت شارپ تا چهار برابر مدل کنترل خرید و نگهداری بیشتر است.
الشووره ^۲ (۲۰۲۴)	۲۰۲۴	هدف اصلی این تحقیق تشکیل یک سبد سرمایه‌گذاری بهینه متشکل از تعدادی سهام انتخاب شده برای پیش‌بینی بازده می‌باشد.	این مطالعه به این نتیجه رسید که پرتفوی تشکیل شده به تنوع خوبی دست یافته و بازده بالایی در رابطه با کمترین ریسک ممکن بر اساس مقیاس شارپ دارد. همچنین نتایج نشان داد که مدل ARMA مناسب‌ترین مدل برای تخمین بازده پرتفوی بازار و پیش‌بینی ریسک بازده شاخص بازار و ARMA و مدل ARMA-GARCH تواناترین مدل‌ها هستند.
ژانگ و همکاران (۲۰۲۴)	۲۰۲۱-۲۰۰۴	هدف از این تحقیق، بررسی تأثیر مدیریت ریسک کل (ریسک نزولی) بین‌زمانی بر عملکرد صندوق‌های مشترک سهامی فعال در چین است.	با بررسی رابطه میان ریسک و بازده در وجوه سرمایه‌گذاری مشترک، نتایج نشان دادند که سود ناشی از مدیریت کلی (نزولی) نوسان‌ها به عواملی مانند زمان‌بندی نوسان‌ها و زمان‌بندی بازده مرتبط است.
دنگ، ونگ و ژو ^۳ (۲۰۲۴)	۲۰۱۹-۱۹۶۸	هدف این تحقیق ساخت یک شاخص جامع شرایط کلان اقتصادی است که انتظارات ذهنی اقتصادی از جمله تولید، تورم و شرایط بازار کار و مسکن را جمع‌بندی می‌کند. این شاخص به پیش‌بینی بازده‌های سهام و تولید پیش‌بینی‌های پرریسک سهام متضاد چرخه‌های اقتصادی کمک می‌کند	نتیجه‌گیری این تحقیق به‌طور کلی به اثبات ارزش و کارایی یک شاخص جامع شرایط کلان اقتصادی می‌انجامد که انتظارات ذهنی از تولید، تورم، و شرایط بازار کار و مسکن را ترکیب می‌کند. یافته‌ها نشان می‌دهند که این شاخص به‌طور مؤثری قادر به پیش‌بینی بازده‌های سهام و تولید پیش‌بینی‌های متضاد چرخه‌ای است که این قابلیت هم در نمونه‌های داخل و هم در نمونه‌های خارج از داده‌ها مورد تأیید قرار گرفته است.

1. Piovezan & Junior
2. Al Shawawreh
3. Deng, Wang & Zhou

نویسندگان	بازه زمانی	هدف	نتیجه
نمازی و کیامهر (۱۳۸۶)	۱۳۷۷-۱۳۸۲	هدف این پژوهش، پیش‌بینی بازده روزانه سهام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی است.	نتایج نشان داد، شبکه‌های عصبی مصنوعی توانایی پیش‌بینی بازده روزانه را با میزان خطای نسبتاً مناسبی دارند.
شریف‌فر، خلیلی عراقی، رئیسی وانانی و فلاح شمس (۱۴۰۰)		هدف کاربرد معماری‌های یادگیری عمیق در پیش‌بینی قیمت سهام با استفاده از رویکرد شبکه عصبی است.	نتایج تحقیق نشان داد که تکنیک‌های یادگیری عمیق، به ویژه پتانسیل قابل توجهی در تجزیه و تحلیل و پیش‌بینی داده‌های سری زمانی مانند قیمت سهام دارند و بینش ارزشمندی را برای تصمیم‌گیری مالی فراهم می‌کنند.
اخباری و همکاران (۱۴۰۳)	۱۳۸۹-۱۳۹۸	هدف بهینه‌سازی پیش‌بینی بازده سهام مبتنی بر ریسک، در صنایع منتخب بورس اوراق بهادار تهران می‌باشد.	نتایج بهینه‌سازی پیش‌بینی بازده سهام در سه صنعت استخراج نفت و گاز به‌جز اکتشاف، استخراج کانه‌های فلزی و فرآورده‌های نفتی نشان داد که صنعت استخراج نفت و گاز بجز اکتشاف با میزان ۰/۴۲۱۴ نسبت به سایر صنایع کارایی بیشتری دارد.

با توجه به بررسی ادبیات پیشینه پژوهش مشاهده می‌شود که مطالعات قبلی تاکنون به بررسی پیش‌بینی بازده سهام و صندوق‌های سرمایه‌گذاری با استفاده از رویکردهای هوش مصنوعی و مدل‌های اقتصادی پرداخته‌اند. به‌طور خاص، این تحقیقات نتایج متفاوتی را در بازارهای توسعه‌یافته و نوظهور گزارش کرده‌اند، اما هیچ‌یک از این مطالعات به‌صورت مستقیم به پیش‌بینی بازده صندوق‌های قابل معامله در کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی نپرداخته‌اند. به‌عنوان مثال، مطالعاتی مانند یو و همکاران (۲۰۲۰) و ما و همکاران (۲۰۲۱) بیشتر به مدل‌های سنتی و یادگیری ماشین برای بازارهای سهام پرداخته‌اند، اما تمرکز ویژه‌ای بر صندوق‌های قابل معامله نداشته‌اند. پژوهش پیووزان و همکاران (۲۰۲۳) نیز با اینکه به مدل‌های طبقه‌بندی و رگرسیون پرداخته است، بازار هدف ویژه‌ای را مشخص نکرده است. بنابراین نوآوری اصلی حاضر در چندین جنبه قابل توجه است. نخست، تمرکز مستقیم بر پیش‌بینی بازده صندوق‌های قابل معامله که از سایر تحقیقات متمایز می‌شود. دوم، پوشش گسترده بازارهای عضو فدراسیون بورس‌های اروپایی و آسیایی که یک ناحیه جغرافیایی خاص با ویژگی‌ها و قوانین ویژه را پوشش می‌دهد (دانقاه، ۲۰۲۳) و این عضو فدراسیون دارای جامعه آماری منظم و در دسترس و شامل هم کشورهای با شرایط اقتصاد توسعه یافته و در حال توسعه است که امکان مقایسه این کشورها را فراهم می‌کند. همچنین، استفاده از تکنیک‌های پیشرفته هوش مصنوعی نظیر یادگیری عمیق و شبکه‌های عصبی که دقت پیش‌بینی را افزایش خواهد داد. در نهایت با توجه به بررسی ادبیات تحقیق عنوانی در این خصوص برای جامعه آماری حاضر و کشور ایران مشاهده نشد که نشان از نوآوری مطالعه حاضر است.

روش‌شناسی پژوهش

پژوهش حاضر از نظر هدف، از نوع تحقیقات کاربردی است. از لحاظ طبقه‌بندی پژوهش بر حسب روش، از نوع تحقیقات توصیفی و از میان انواع روش‌های تحقیقات توصیفی، از نوع پژوهش‌های هدفمند است. جامعه آماری این پژوهش، داده‌های صندوق‌های قابل معامله در بورس اوراق بهادار ایران و سایر کشورهای جهان است که از طریق سایت فدراسیون بورس‌های اوراق بهادار اروپا و آسیا^۱ و سایت بورس اوراق بهادار تهران برای بازه ۲۰۱۵ تا آخر سال ۲۰۲۳ استخراج شد. داده‌ها با استفاده نرم‌افزار اکسل مرتب شد. در راستای دستیابی به جامعه آماری مناسب و هدفمند، انتخاب نمونه از روش غربالگری (حذفی) استفاده شد. صندوق‌های انتخابی از ویژگی‌های زیر برخوردار بودند (چوی و کیم^۲، ۲۰۲۴؛ پیووزان و همکاران، ۲۰۲۳):

۱. در بازه زمانی مورد مطالعه تأسیس شده باشند؛
۲. تغییر سال مالی نداشته باشند؛
۳. سه سال متوالی زیان نداده نباشند؛
۴. توقف معاملاتی بیشتر از ۶ ماه نداشته باشند؛
۵. جزء صندوق‌های معروف و بزرگ باشند.

در توضیح ویژگی آخر، بایستی گفت که بزرگ‌ترین صندوق‌های سرمایه‌گذاری از نظر حجم معاملات در هر کشور انتخاب شده است؛ زیرا صندوق‌های بزرگ و معروف، معمولاً به دلیل مزایای متعددی مورد توجه قرار می‌گیرند. این صندوق‌ها به واسطه حجم انبوه سرمایه تحت مدیریت، امکان تنوع‌بخشی بیشتر به سبد سرمایه‌گذاری و کاهش ریسک را دارند. همچنین، از مزایای صرفه‌جویی در مقیاس بهره‌مند می‌شوند که به کاهش هزینه‌های عملیاتی نسبت به حجم سرمایه منجر می‌شود. شهرت این صندوق‌ها نیز معمولاً نشان‌دهنده سابقه موفق، مدیریت حرفه‌ای و شفافیت بیشتر است. صندوق‌های بزرگ و معروف اغلب توسط مؤسسه‌های مالی شناخته شده مدیریت می‌شوند، سابقه طولانی و عملکرد قابل قبولی دارند، و اطلاعات دقیق و به‌روزی از عملکرد و استراتژی‌های خود ارائه می‌دهند. این ویژگی‌ها باعث می‌شود که این صندوق‌ها برای سرمایه‌گذاران جذاب‌تر باشند و اعتماد بیشتری را جلب کنند. بدین ترتیب، پس از جمع‌آوری اطلاعات ۱۰۲۴ صندوق جهانی موجود در سایت‌های مذکور، نسبت به حذف صندوق‌های فاقد ویژگی فوق اقدام شد و در نهایت تعداد ۳۶۰ صندوق برای پیاده‌سازی مدل انتخاب شد که به‌عنوان جامعه هدف پژوهش مورد بررسی قرار گرفتند. همچنین برای تجزیه و تحلیل داده‌ها از نرم‌افزارهای R&Rstudio استفاده شد. در نتیجه، تأکید اصلی این تحقیق بر انتخاب صندوق‌هایی است که بازده بالا دارند.

به‌منظور بررسی هدف پژوهش لازم است که با توجه به مبانی نظری پژوهش عوامل مؤثر بر متغیر وابسته بازده صندوق سرمایه‌گذاری را گرد هم آورد و آن را براساس تابعی همچون F بیان کرد. این تابع به‌شکل غیرخطی معین

می‌شود. بدین منظور ابتدا با استفاده از هوش مصنوعی پیش‌بینی، بازده صندوق پیش‌بینی می‌شود و سپس با استفاده از مدل‌های سنجی فضایی، رابطه فضایی بین صندوق‌ها و متغیرها بررسی می‌شود و در نهایت، برای مقایسه بهتر از خروجی مدل فضایی به‌عنوان ورودی مجدد، از هوش مصنوعی برای پیش‌بینی دقیق‌تر بازده صندوق‌ها استفاده می‌شود. بدین ترتیب، ترکیب هوش مصنوعی با اقتصادسنجی فضایی یک رویکرد نوآورانه و قوی برای تحلیل و پیش‌بینی بازده صندوق‌های سرمایه‌گذاری است. این ترکیب به‌دلایل متعددی انجام می‌شود: اول اینکه، هوش مصنوعی قادر است الگوهای پیچیده و غیرخطی را در داده‌ها شناسایی کند که ممکن است برای روش‌های سنتی قابل تشخیص نباشد. دوم، اقتصادسنجی فضایی امکان در نظر گرفتن وابستگی‌های مکانی و ارتباطات بین صندوق‌ها را فراهم می‌کند که در تحلیل‌های معمولی نادیده گرفته می‌شوند. بنابراین، ترکیب این دو روش اجازه می‌دهد تا ابتدا با استفاده از هوش مصنوعی، پیش‌بینی اولیه انجام شود، سپس با استفاده از مدل‌های فضایی، روابط مکانی و هم‌بستگی‌های بین صندوق‌ها و متغیرها بررسی شود و در نهایت، نتایج حاصل از تحلیل فضایی به‌عنوان ورودی جدید برای هوش مصنوعی استفاده شود تا پیش‌بینی دقیق‌تر و جامع‌تری از بازده صندوق‌ها ارائه دهد. این رویکرد ترکیبی، دقت پیش‌بینی را افزایش داده و درک عمیق‌تری از عوامل مؤثر بر بازده صندوق‌های سرمایه‌گذاری فراهم می‌کند. بدین ترتیب، بر اساس مطالعات گورکاینک، ساک و رایت^۱ (۲۰۰۷)؛ گارگانو، پتنوزو و تیمرمن^۲ (۲۰۱۹) و دانیل، کریستنسن، موله‌باخ و نیلسن^۳ (۲۰۲۴) و بالی و همکاران (۲۰۱۴) و دنگ و همکاران (۲۰۲۴) مدل پژوهش حاضر برای پیش‌بینی بازده صندوق سرمایه‌گذاری با استفاده از هوش مصنوعی به شرح رابطه ۱ است.

$$rx_{it} = f(S, T, J, B, A, G, E, M, I, L, Rm, C, \pi, GDP, ir, ER) \quad \text{رابطه ۱}$$

از سویی دیگر، برای بررسی رابطه فضایی بین صندوق‌ها و متغیرها از مدل خودرگرسیون فضایی استفاده می‌شود که به شرح رابطه ۲ است.

$$\begin{aligned} rx_{it} = & \lambda Wrx_{it} + \beta_0 + \beta_1 s_{it} + \beta_2 T_{it} + \beta_3 J_{it} + \beta_4 B_{it} + \beta_5 A_{it} + \beta_6 G_{it} + \beta_7 E_{it} \\ & + \beta_8 M_{it} + \beta_9 I_{it} + \beta_{10} L_{it} + \beta_{11} Rm_{it} + \beta_{12} C_{it} + \beta_{13} \pi_{it} + \beta_{14} GDP_{it} \\ & + \beta_{15} ir_{it} + \beta_{16} ER_{it} + \varphi_{it} \end{aligned} \quad \text{رابطه ۲}$$

در نهایت، رابطه ۳، نشان‌دهنده ترکیب، مدل‌های هوش مصنوعی با مدل اقتصادسنجی فضایی است که برای پیش‌بینی نهایی استفاده می‌شود.

$$\begin{aligned} rx_{it} = & f(S, T, J, B, A, G, E, M, I, L, Rm, C, \pi, GDP, ir, ER) \\ & + \lambda Wf(S, T, J, B, A, G, E, M, I, L, Rm, C, \pi, GDP, ir, ER) + \varphi_{it} \end{aligned} \quad \text{رابطه ۳}$$

1. Gurkaynak, Sack & Wright
2. Gargano, Pettenuzzo & Timmermann
3. Danil, Christensen, Mühlbach & Nielsen

که در روابط بالا، rx_{it} بیانگر بازده صندوق؛ S نسبت شارپ؛ T نسبت ترینر؛ J نسبت جنسن؛ B نسبت دوره برتر؛ اندازه صندوق؛ G رشد ارزش صندوق؛ E خبرگی مدیریت صندوق؛ M میانگین ماهانه؛ I درصد سرمایه‌گذاران حقیقی؛ L عمر صندوق؛ Rm : بازده بازار؛ C درصد دارایی‌های نقدی؛ π : تورم؛ GDP : تولید ناخالص داخلی؛ ir : نرخ بهره؛ ER : نرخ ارز و φ : بیانگر پسماند است.

در اصل، بازده صندوق به مقدار سود یا زیانی اشاره دارد که یک سرمایه‌گذاری در یک دوره زمانی مشخص به دست می‌آورد. این مقدار می‌تواند به صورت نسبی (درصدی) یا مطلق (مقدار پولی) بیان شود و به عنوان متغیر وابسته این پژوهش مورد بررسی قرار می‌گیرد. برای صندوق‌های قابل معامله، بازده می‌تواند از تغییرات قیمت واحدهای سرمایه‌گذاری صندوق و همچنین از درآمدهای توزیع شده به دست آید. بنابراین در این مطالعه، بازده صندوق‌های سرمایه‌گذاری بر اساس رابطه ۴ به دست آمده است.

$$rx_{t+\tau}^k = p_{t+\tau}^{k-\tau} + p_t^k + p_t^\tau \quad \text{رابطه ۴}$$

که در آن، $(rx_{t+\tau}^k)$ بازده بیش از حد نگهداری دوره‌ای به مدت t ماه روی صندوق سرمایه‌گذاری با سررسید k ماه است. p_t^k قیمت لگاریتمی صندوق در زمان t با سررسید k ماه است.

همان طور که در رابطه ۴ نشان داده شده، داده‌های مورد استفاده برای محاسبه بازده صندوق‌های سرمایه‌گذاری، از قیمت‌های پایانی صندوق‌های ماهانه استفاده شده است. بنابراین برای اندازه‌گیری بازده صندوق، ابتدا قیمت اوراق قرضه در بازه‌های زمانی مشخص جمع‌آوری می‌شود. سپس، بازده‌های ماهانه بر اساس تغییرات قیمت‌ها محاسبه می‌شوند. در این پژوهش، محاسبه بازده‌های ماهانه به جای بازده‌های سالانه مزایای خاصی ارائه می‌دهد، از جمله کاهش مشکلات ناشی از هم‌پوشانی^۱ بازده‌های زمانی سالانه که می‌تواند به خطا در روش‌های آماری منجر شود (بائر و همیلتون، ۲۰۱۸). همچنین، بازده‌های ماهانه این امکان را فراهم می‌کنند که تحركات کوتاه مدت در بازده‌های اوراق قرضه که ممکن است در بازه‌های سالانه نادیده گرفته شوند، بهتر شناسایی شوند (گارگانو و همکاران، ۲۰۱۹). استفاده از بازده‌های ماهانه همچنین این امکان را می‌دهد که تحلیل پس از رویدادهای مختلف اقتصادی با دقت بیشتری انجام شود؛ زیرا بازده‌های هم‌پوشانی ممکن است به صورت چندین دوره اقتصادی مختلف را پوشش دهند و تفسیر نتایج را دشوار کنند. بنابراین، استفاده از داده‌های ماهانه به تطبیق سریع‌تر با محیط‌های پیش‌بینی متغیر کمک می‌کند (کشاورز حداد، ابراهیم نژاد و گروسی، ۱۴۰۱). بنابراین در این پژوهش هم راستای مطالعه چاوشی (۱۳۹۲) متغیرهای مستقل به شرح جدول ۲ معرفی شده است.

1. overlapping
2. Bauer & Hamilton

جدول ۲. تعریف عملیاتی متغیرهای مستقل پژوهش

منبع	محاسبه ریاضی	تعریف عملیاتی	متغیر
شارپ ^۱ (۱۹۹۴)	$S = \frac{R_p - R_f}{\sigma_p}$	بازدهی اضافی (مازاد بر نرخ بدون ریسک) بر انحراف معیار بازده تقسیم می‌شود.	نسبت شارپ - دوره قبل
تری‌نور ^۲ (۱۹۶۵)	$T = \frac{R_p - R_f}{\beta_p}$	بازدهی اضافی را بر ریسک سیستماتیک (بتا) تقسیم می‌کند.	نسبت تری‌نور - دوره قبل
جنسن ^۳ (۱۹۶۸)	$J = R_p - (R_f + \beta_p(R_m - R_f))$	تفاوت بین نرخ بازده واقعی صندوق و نرخ بازده مورد انتظار بر اساس مدل CAPM	معیار جنسن - دوره قبل
الینگ و شوماخر ^۴ (۲۰۰۷)	$R > R_m$ نسبت دوره برتر = $\frac{R - R_m}{p}$ کل روزها	نسبت تعداد روزهایی که بازدهی صندوق بالاتر از بازده بازار است بر کل روزهای دوره.	نسبت دوره برتر - دوره قبل
چن، هونگ، هوانگ و کوبیک ^۵ (۲۰۰۴)	اندازه صندوق = $\log(V_f)$	برابر با لگاریتم طبیعی ارزش صندوق است	اندازه صندوق
سیری و توفانو ^۶ (۱۹۹۸)	رشد ارزش صندوق = $\frac{V_{f\text{پایان}} - V_{f\text{شروع}}}{V_{f\text{شروع}}}$	برابر با رشد خالص ارزش کل دارایی‌های آن می‌باشد.	رشد ارزش صندوق
کاپرچیک، سیالم و ژنگ ^۷ (۲۰۰۵)	از گزارش‌های رتبه‌بندی کارگزاری‌ها که سازمان رسمی معاملات سهام هر کشور منتشر می‌کند، استفاده شده است.	از گزارش‌های رتبه‌بندی کارگزاری‌ها استفاده شده است.	خبرگی مدیریت صندوق
بولن و باس ^۸ (۲۰۰۵)	میانگین بازدهی ماهانه = $\frac{\sum R}{N}$	از تقسیم بازدهی کل بر عمر آن حاصل می‌شود.	میانگین بازدهی ماهانه
گرینبلات و کلوهارجو ^۹ (۲۰۰۰)	درصد سرمایه‌گذاران حقیقی = $\sum i$ درصد سرمایه‌گذاری حقیقی در صندوق	مجموع درصد سرمایه‌گذاری حقیقی در صندوق ا در دوره t	درصد سرمایه‌گذاران حقیقی
آگاروال و جورین ^{۱۰} (۲۰۱۰)	عمر صندوق = n	تعداد ماههایی که از تأسیس صندوق مشترک گذشته است.	عمر صندوق
فاما و فرنچ ^{۱۱} (۱۹۹۳)	$R_m = \frac{\text{شاخص پایان دوره} - \text{شاخص شروع دوره}}{\text{شاخص شروع دوره}}$	بازده شاخص بورس در دوره t	بازده بازار

1. Sharpe
2. Treynor
3. Jensen
4. Eling & Schuhmacher
5. Chen, Hong, Huang & Kubik
6. Sirri & Tufano
7. Kacperczyk, Sialm & Zheng
8. Bollen & Busse
9. Grinblatt & Keloharju
10. Aggarwal & Jorion

منبع	محاسبه ریاضی	تعریف عملیاتی	متغیر
سیموتین ^۱ (۲۰۱۰)	درصد های دارایی نقدی اوراق مشارکت + گواهی سپرده = مجموع درصد وجه نقد +	مجموع دارایی های با نقدشوندگی بالا.	درصد دارایی های نقدی
فاما و شورت ^۲ (۱۹۹۷)	$\pi = \frac{CPI_{\text{پایان دوره}} - CPI_{\text{شروع دوره}}}{CPI_{\text{پایان دوره}}}$	میزان تغییرات قیمت کالاها و خدمات در یک دوره زمانی.	تورم
جوریون ^۳ (۱۹۹۱)	نرخ ارز به طور عمومی به عنوان قیمت یک واحد از ارز یک کشور به ارز کشور دیگر بیان می شود. اگر بخواهیم آن را به صورت معادله ای ساده بیان کنیم: $\text{قیمت واحد ارز کشور مرجع} = \text{نرخ ارز}$ $\text{قیمت واحد ارز کشور مقصد}$	نرخ تبادل ارز بین دو کشور. به عنوان مثال، اگر نرخ یورو به دلار ۱.۱۰ باشد، این بدان معناست که ۱ یورو برابر با ۱.۱۰ دلار آمریکا است.	نرخ ارز
کمبل و آمر ^۴ (۱۹۹۳)	$\text{نرخ بهره اسمی} + 1 = \frac{\text{نرخ بهره واقعی}}{\text{نرخ تورم} + 1} - 1$ این فرمول نشان دهنده نرخ سود حقیقی است که پس از تعدیل از تأثیرات تورم بر نرخ بهره اسمی حاصل می شود.	هزینه های که مصرف کنندگان برای استقراض از بانک پرداخت می کنند.	نرخ بهره واقعی
فرسون و هاروی ^۵ (۱۹۹۱)	$GDP = C + I + G + (X - M)$	مجموع ارزش تولید داخلی در یک کشور.	تولید ناخالص داخلی

معرفی نمادهای جدول:

R_p : بازده واقعی صندوق؛

R_f : نرخ بازده بدون ریسک

σ_p : انحراف معیار بازده صندوق؛

β_p : بتای صندوق؛

R_m : بازده بازار؛

V_f : ارزش کل صندوق؛

n : تعداد ماه ها؛

R : بازدهی کل؛

C : مخارج مصرفی خانوار یا مصرف خصوصی؛

I : سرمایه گذاری های انجام شده توسط کسب و کارها (مانند خرید تجهیزات و ساخت و ساز)؛

G : مخارج دولتی (شامل هزینه های جاری و سرمایه گذاری های دولت)؛

X : صادرات کالاها و خدمات؛

M : واردات کالاها و خدمات؛

CPI : شاخص قیمت مصرف کننده؛

1. Simutin
2. Fama & Schwert
3. Jorion
4. Campbell & Ammer
5. Ferson & Harvey

مدل‌های پیش‌بینی

در این تحقیق برای پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک از مدل‌های هوش مصنوعی، ترکیب مدل‌های هوش مصنوعی با تکنیک‌های اقتصادسنجی فضایی و رویکرد ترکیبی هوش مصنوعی و پانل هیبرید فضایی استفاده شده است که به توضیح مدل‌های که در تحقیقات استفاده شده، پرداخته شده است.

ماشین بردار پشتیبانی^۱

ماشین بردار پشتیبانی اولین بار در سال ۱۹۹۵ توسط کورتزو و پنیگ (۱۹۹۵) معرفی شد. این یک الگوریتم یادگیری ماشین نظارت شده است که در صنایع مختلف برای حل مشکلات رگرسیون و طبقه‌بندی استفاده می‌شود (پانت و کومار^۲، ۲۰۲۲). برای مسائل طبقه‌بندی، ماشین بردار پشتیبانی به‌عنوان رویکردی که بزرگ‌ترین ابر صفحه حاشیه را ایجاد می‌کند تا حداکثر تفکیک را بین کلاس‌های مختلف ارائه دهد، محبوب است. نمونه‌هایی که برای یک مسئله یادگیری معین به ماکزیمم هایپرصفحه حاشیه نزدیک هستند، بردارهای پشتیبانی نامیده می‌شوند. تابع متمایز نیز ممکن است خطی یا غیرخطی باشد. اگر مورد به‌صورت خطی قابل تفکیک باشد، می‌توان از یک ابر صفحه خطی برای تقسیم نمونه‌ها استفاده کرد؛ در غیر این صورت، وضعیت به‌صورت غیرخطی قابل تفکیک است (چیا و همکاران، ۲۰۲۲). مدل‌های ماشین بردار پشتیبانی بیشتر توسعه یافته‌اند تا طیف گسترده‌تری از مدل‌های ماشین بردار پشتیبانی، چالش‌های تخمین عمومی و پیش‌بینی را دربرگیرند. این گسترش به معرفی رگرسیون بردار پشتیبانی، توسط دراکر و همکارانش در سال ۱۹۹۶ منجر شده است.

رگرسیون بردار پشتیبانی^۳

رگرسیون بردار پشتیبانی یک مدل یادگیری ماشین کلاسیک است که به‌طور گسترده در پیش‌بینی بازار سهام استفاده شده است (لو، لی و چیو^۴، ۲۰۰۹؛ ماتیا و ربورده^۵، ۲۰۱۲؛ راسل، سلطانا و میصاد^۶، ۲۰۱۵). رگرسیون بردار پشتیبانی از تکنیک‌های بهینه‌سازی محدب برای تبدیل مسائل پیچیده رگرسیون غیرخطی به مسائل رگرسیون خطی استفاده می‌کند. از طریق این تبدیل، تنظیمی بین پیچیدگی مدل و خطای تجربی ایجاد شده است که دقت پیش‌بینی بالایی را فراهم می‌کند (بهرا، پاسایات، بهرا و کومار^۷، ۲۰۲۳). در رگرسیون بردار پشتیبانی، رابطه^۵، یک ارتباط غیرخطی بین متغیرهای تصادفی X و Y را نشان می‌دهد که این ارتباط از طریق تابع خطی f تبیین می‌شود.

$$f(x) = w\phi(x) + b \quad (\text{رابطه } ۵)$$

1. Support vector machine (SVM)
2. Pant & Kumar.
3. Support vector regression (SVR)
4. Lu, Lee & Chiu
5. Matías & Reboredo
6. Rasel, Sultana & Meesad
7. Behera, Pasayat, Behera & Kumar

تقویت گرادیان^۱ (XGBoost)

تقویت گرادیان یک جعبه ابزار تقویت گرادیان توزیع شده است که برای عملکرد تنظیم شده است (بهره و همکاران، ۲۰۲۳). از یک استراتژی پارامتریک باینری بازگشتی برای به دست آوردن مدل بهینه با انتخاب بهترین پارامتر در هر مرحله استفاده می‌کند. ماهیت درختی تقویت گرادیان آن را نسبت به موارد دور افتاده غیر حساس می‌کند و مانند بسیاری از روش‌های تقویت، در برابر مشکل بیش از حد برازش مقاوم است که انتخاب مدل را بسیار ساده‌تر می‌کند (بهره و همکاران، ۲۰۲۳؛ العبدالله و همکاران^۲، ۲۰۲۲؛ پاسایت، میترا و بهمیک^۳، ۲۰۲۴). در رابطه^۶ که به مدل تقویت گرادیان مربوط می‌شود، هدف از آموزش این است که ضرر یا هزینه بین پیش‌بینی‌های مدل و مقادیر واقعی (حقیقت زمینه) محاسبه شود.

$$L^{(t)} = \sum_i l(y_{pred}^{(t)}, y_{truth}) + \sum_k \Omega(f_k) \quad \text{رابطه ۶}$$

y_{truth} مقادیر واقعی، $y_{pred}^{(t)}$ پیش‌بینی‌های مدل، Ω نشان‌دهنده پیچیدگی درخت k و T تعداد برگ‌ها.

جنگل تصادفی^۴

جنگل تصادفی یک مدل ناپارامتریک و غیرخطی است که برای اولین بار توسط هو (۱۹۹۵) ارائه شد. این مدل از مشکل بیش از حد برازش اجتناب می‌کند؛ زیرا همیشه همگرا می‌شود. با توجه به مزایای جنگل تصادفی، اغلب برای پیش‌بینی سهام استفاده می‌شود (بالینگز، پائول، هسپیلز و گریپ^۵، ۲۰۱۵). تعیین پیش‌بینی با توجه به نوع مشکل متفاوت خواهد بود. در مورد طبقه‌بندی، درخت‌های تصمیم در مدل پیش‌بینی القا شده با جنگل تصادفی در یک گروه مرتب می‌شوند و نتیجه با پیش‌بینی‌های انجام شده توسط هر درخت، مانند استفاده از اکثریت رای تعیین می‌شود (تنگ، هندرسون و گاردنر^۶، ۲۰۲۱). در همین حال، میانگین پیش‌بینی درختان، پیش‌بینی نهایی را در رگرسیون تشکیل می‌دهد؛ یعنی وقتی جنگل تصادفی یک بردار ورودی (x) حاوی مقادیر بسیاری از ویژگی‌های مشهودی را که برای یک ناحیه آموزشی خاص بررسی شده است، دریافت می‌کند، درخت‌های رگرسیون m تولید می‌کند و سپس نتایج را میانگین می‌گیرد.

رابطه^۷ به پیش‌بینی مدل جنگل تصادفی اشاره دارد که از مجموعه‌ای از m درخت تصمیم به نام $\{T(x)\}_1^M$ تشکیل شده است. در این مدل، هر درخت تصمیم به تنهایی به پیش‌بینی خروجی کمک می‌کند و جمع‌بندی این پیش‌بینی‌ها از تمام درختان، به تولید یک پیش‌بینی نهایی و دقیق‌تر برای ورودی x منجر می‌شود (بهره و همکاران، ۲۰۲۳).

1. Gradient boosting
2. Alabdullah et al.
3. Pasayat, Mitra & Bhowmick
4. Random forest
5. Ballings, Poel, Hespeels & Gryp
6. Tang, Henderson & Gardner

$$f_{rf}^M(x) = \frac{1}{M} \sum_{m=1}^M T(x) \quad \text{رابطه ۷}$$

شبکه‌های عصبی مصنوعی^۱

شبکه‌های عصبی مصنوعی تلفیقی از مفاهیم مختلف یادگیری ماشین، از جمله رگرسیون، مجموعه، پرسپترون‌ها و نزول گرادینان است. ترکیبی خطی از متغیرهای ورودی را می‌گیرد و آن‌ها را به توابع غیرخطی از ویژگی‌های مشتق شده متغیر وابسته تبدیل می‌کند (میشرا، داسگوپتا، پاترا، پال و آناند^۲، ۲۰۲۲). آن‌ها ابتدایی‌ترین نوع شبکه‌های عمیق هستند که از لایه‌های متعددی از نورون‌های پنهان تشکیل شده‌اند که هر کدام به‌طور کامل به لایه بالا (که از آن تأثیر می‌گذارند) و زیر (که از آن ورودی دریافت می‌کنند) متصل هستند (ساهو و همکاران^۳، ۲۰۲۲). با در نظر گرفتن شبکه‌هایی با لایه‌های فزاینده واحدهای به هم پیوسته، می‌توان هر عملکرد کلی را ساخت. ترکیب خطی وزنی ورودی‌ها توسط هر لایه پردازش شده و با استفاده از یک تابع فعال سازی تبدیل می‌شود.

رابطه ۸ به خروجی واحد زام در یک شبکه عصبی اشاره دارد که با استفاده از وزنی به نام w_{ji}^1 محاسبه می‌شود. این وزن نشان‌دهنده ارتباط و تأثیر واحد i ام در لایه ۱ روی واحد زام است. به عبارت دیگر، خروجی واحد زام به میزان تأثیر و وزنی که از واحد i ام در لایه ۱ دریافت می‌کند، بستگی دارد.

$$Z_j = g \left(\sum_{i=0}^d w_{ji}^1 x_i \right) \quad \text{رابطه ۸}$$

شبکه عصبی پرسپترون چند لایه^۴

شبکه‌های عصبی نوعی مدل‌سازی ساده‌انگارانه از سیستم عصبی واقعی هستند که در حل مسائل مختلف در علوم کاربرد فراوانی دارند. حوزه کاربرد این شبکه‌ها آن‌چنان گسترده است که از کاربردهای طبقه‌بندی گرفته تا کاربردهایی نظیر درون‌یابی، تخمین، آشکارسازی و... را شامل می‌شوند. شبکه‌ها انواع مختلفی دارند؛ اما همگی آن‌ها از دو مؤلفه تشکیل می‌شوند: مجموعه‌ای از نرون‌ها و اتصالات بین نرون‌ها. هر نرون در حقیقت واحد محاسباتی شبکه است که ورودی‌ها را می‌گیرد و روی آن پردازش انجام می‌دهد تا خروجی به‌دست آید. یکی از ساده‌ترین و در عین حال کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی عصب‌های واقعی، مدل پرسپترون چندلایه یا به اختصار شبکه عصبی پرسپترون چند لایه است که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. در این ساختار، تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصل هستند. این چیدمان به اصطلاح، یک شبکه با اتصالات کامل را تشکیل می‌دهد (رجبی، عسگری و دهقان، ۱۳۹۷).

1. Artificial neural network (ANN)
2. Mishra, Dasgupta, Patra, Pal & Anand
3. Sahu et al.
4. Multi Layer Perceptron

شبکه عصبی مخچه^۱

کامپیوتر محاسباتی مدل مخچه‌ای نوعی شبکه عصبی نظارتی است. همچنین به‌عنوان کنترل‌کننده مفصلی مدل مخچه‌ای شناخته می‌شود. نوعی حافظه تداوی است. این شبکه عصبی ابتدا توسط آلبوس در سال‌های ۱۹۷۵ معرفی شد و بر اساس عملکردهای مخچه انسان طراحی شده است که مسئول کنترل عضلات و هماهنگی حرکتی است و به‌طور گسترده در یادگیری تقویتی و همچنین برای طبقه‌بندی خودکار در جامعه یادگیری ماشین استفاده شده است. مدل مخچه‌ای توسعه مدل پرسپترون است. تابعی را برای n بعد ورودی محاسبه می‌کند. فضای ورودی به بیش‌مستطیل‌هایی تقسیم می‌شود که هر کدام با یک سلول حافظه مرتبط هستند. محتویات سلول‌های حافظه وزنه‌هایی هستند که در حین تمرین تنظیم می‌شوند. معمولاً بیش از یک کوانتیزه سازی فضای ورودی استفاده می‌شود، به‌طوری که هر نقطه در فضای ورودی با تعدادی بیش‌مستطیل و در نتیجه با تعدادی سلول حافظه همراه است. خروجی یک مدل مخچه‌ای مجموع جبری وزن‌های تمام سلول‌های حافظه است که توسط نقطه ورودی فعال می‌شوند (لو و وو، ۲۰۱۱).

شبکه‌های عصبی نئوکلاسیک^۲

شبکه‌های عصبی نئوکلاسیک به مجموعه‌ای از مدل‌های شبکه‌های عصبی اشاره دارند که از اصول و ساختارهای کلاسیک شبکه‌های عصبی بهره می‌برند، به‌ویژه شبکه‌های چندلایه یا شبکه‌های پرسپترون چندلایه که اغلب برای مسائل یادگیری عمیق استفاده می‌شوند. این شبکه‌ها معمولاً شامل لایه‌های ورودی، لایه‌های مخفی و یک لایه خروجی هستند و با استفاده از الگوریتم‌های پس‌انتشار خطا^۳ آموزش می‌بینند. در شبکه‌های عصبی نئوکلاسیک، هر واحد (یا نورون) در یک لایه به نورون‌های لایه قبل و بعد متصل است و خروجی هر نورون با استفاده از یک تابع فعال‌سازی محاسبه می‌شود. مراحل محاسبه به‌صورت رابطه^۹ است. هر نورون ورودی را از طریق وزن‌های متناسب w_{ji} دریافت می‌کند (گودفیلو، بنیگو و کورویل^۴، ۲۰۱۶).

$$z_j = \sum_i w_{ji} \cdot x_i + b_j \quad \text{رابطه ۹}$$

x_i ورودی‌ها هستند

الگوریتم جنگل خشن تصادفی^۵

مدل‌های جنگل خشن تصادفی به‌عنوان یکی از الگوریتم‌های محبوب یادگیری ماشین، توانایی بالایی در پیش‌بینی در حوزه‌های مختلف از جمله مالی دارند. الگوریتم جنگل خشن تصادفی یک تکنیک یادگیری جمعی هست که برای حداقل کردن واریانس مدل استفاده می‌شود و می‌تواند برای مسائل خطی و غیرخطی نیز به‌کار رود. این مدل به‌خصوص برای

1. CMAC
2. Neoclassical Neural Network
3. Backpropagation
4. Goodfellow, Bengio & Courville
5. Random Rough Forest Algorithm

پیش‌بینی قیمت دارایی‌ها، مدیریت ریسک و تحلیل بازارهای مالی مناسب است. برای یک ورودی جدید x ، نتیجه پیش‌بینی توسط M درخت به صورت رابطه ۱۰ محاسبه می‌شود. (السلطان و البلطح^۱، ۲۰۲۴).

$$\hat{y} = \frac{1}{M} \sum_{m=1}^M T_m(x) \quad \text{رابطه ۱۰}$$

اینجا $T_m(x)$ خروجی m امین درخت تصمیم است که برای ورودی x محاسبه شده است.

مدل‌های سنجی فضایی^۲

مدل‌های سنجی فضایی یکی از روش‌های تحلیلی در اقتصاد و علوم اجتماعی هستند که به بررسی و پیش‌بینی روابط میان متغیرهای مستقل و وابسته با تأکید بر خصوصیات فضایی می‌پردازند. این مدل‌ها می‌توانند به تحلیل داده‌هایی بپردازند که در فضای جغرافیایی توزیع شده‌اند و تأثیرات میان نواحی یا نقاط مختلف را در نظر بگیرند. در حوزه مالی، کاربرد مدل‌های سنجی فضایی شامل تحلیل ارتباط میان متغیرهای مالی مانند قیمت‌ها، بازده سرمایه‌گذاری، و ریسک در مناطق مختلف جغرافیایی است. به عنوان مثال، قیمت سهام در یک بازار ممکن است تحت تأثیر قیمت سهام در بازارهای همسایه قرار گیرد (لیسیج و پیس^۳، ۲۰۰۹). مدل‌های سنجی فضایی معمولاً به دو دسته اصلی تقسیم می‌شوند: ۱. مدل‌های خودهم‌بستگی فضایی^۴ و ۲. مدل‌های اثرهای فضایی^۵.

در پژوهش حاضر از مدل اول استفاده شده است. این نوع مدل‌ها زمانی به کار می‌روند که مقدار یک متغیر تحت تأثیر مقادیر همسایگان آن متغیر قرار دارد. فرمول کلی برای مدل، به صورت رابطه ۱۱ است:

$$Y = \rho WY + X\beta + \epsilon \quad \text{رابطه ۱۱}$$

Y و X به ترتیب متغیر وابسته و ماتریس متغیرهای مستقل هستند. W ماتریس همسایگی است که روابط فضایی بین واحدها را نشان می‌دهد. P پارامتر خودهم‌بستگی فضایی است. B ضرایب مدل است و ϵ خطاهای تصادفی است. با توجه به مدل‌های ارائه شده، معیارهای سنجش عملکرد مدل‌ها به شرح زیر است.

میانگین خطای مطلق^۶

میانگین خطای مطلق به وسیله میانگین تفاوت مطلق بین ارزش واقعی و پیش‌بینی شده در کل مجموعه داده برآورد می‌شود. به بیان ریاضی، میانگین حسابی خطای مطلق است. MAE به سادگی بزرگی خطاها را اندازه‌گیری می‌کند و به جهت آن‌ها اهمیتی نمی‌دهد. هرچه MAE کمتر باشد، یک مدل دقیق‌تر است. از رابطه ۱۲ برای محاسبه میانگین باقی‌مانده مجموعه داده استفاده می‌شود (بهره و همکاران، ۲۰۲۳؛ الاوراسان و همکاران، ۲۰۱۸).

1. Al-Sultan & Al-Baltah
2. Spatial econometrics
3. LeSage & Pace
4. Spatial Autoregressive Models-SAR
5. Spatial Error Models-SEM
6. Mean Absolute Error (MAE)

$$MAE = \frac{1}{N} \sum_{j=1}^N |y_j - \hat{y}_j| \quad \text{رابطه ۱۲}$$

y_j مقادیر واقعی، \hat{y}_j مقادیر پیش‌بینی شده است.

میانگین مربعات خطا^۱

میانگین مربعات خطا (MSE) اندازه‌گیری نزدیکی یک خط رگرسیون به گروهی از نقاط است. این با گرفتن مجذور فواصل بین خط رگرسیون و نقاط تعیین می‌شود. برای از بین بردن هر گونه علائم منفی، مجذور کردن ضروری است. از آنجایی که میانگین مجموعه‌ای از خطاها با این مورد تعیین می‌شود، به آن میانگین مربعات خطا می‌گویند. هرچه میانگین مربعات خطا کمتر باشد، پیش‌بینی دقیق‌تر است. فرمول محاسبه MSE رابطه ۱۳ آمده است (بهره‌ا و همکاران، ۲۰۲۳).

$$MSE = \frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2 \quad \text{رابطه ۱۳}$$

ریشه میانگین مربعات خطا^۲

انحراف استاندارد خطاهای پیش‌بینی (باقی‌مانده) به‌عنوان ریشه میانگین مربعات خطا (RMSE) شناخته می‌شود. این اندازه‌گیری میزان پراکندگی باقی‌مانده‌ها را ارائه می‌دهد، جایی که باقی‌مانده میزان انحراف نقاط داده از خط رگرسیون را اندازه‌گیری می‌کند. به عبارت دیگر، غلظت داده‌ها را در حول بهترین خط مناسب اعلام می‌کند. در اقلیم‌شناسی، تحلیل رگرسیون و پیش‌بینی، ریشه میانگین مربعات خطا اغلب برای تأیید نتایج آزمایش‌ها استفاده می‌شود. می‌توان آن را به‌صورت رابطه ۱۴ تعریف کرد (بهره‌ا و همکاران، ۲۰۲۳؛ هو و همکاران ۲۰۲۱).

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2} \quad \text{رابطه ۱۴}$$

ضریب تعیین

توان دوم ضریب هم‌بستگی خطی میزان هم‌بستگی بین دو متغیر (داده‌های محاسباتی و داده‌های واقعی) را تعیین می‌کند، ضریب تعیین هم‌بستگی خطی می‌نامند که طبق رابطه ۱۵ محاسبه می‌شود (خسرویانی و حیدرپور، ۱۴۰۱).

1. Mean Squared Error (MSE)
2. Root mean squared error (RMSE)

$$R^2 = \frac{\sum_1^n (calc - avg. obs)^2}{\sum_1^n (obs - avg. obs)^2} \quad \text{رابطه ۱۵}$$

obs.avg میانگین داده‌های واقعی؛ Obs داده‌های واقعی؛ n تعداد کل زوج داده‌های واقعی و محاسبه شده توسط؛ مدل؛ calcs داده‌های محاسبه شده توسط مدل متناظر با داده‌های واقعی. مقدار ایدئال برای ضریب تعیین، ۱ است.

درصد خطای مطلق میانگین^۱

یک معیار ارزیابی دقت پیش‌بینی‌ها است که معمولاً در تحلیل‌های سری زمانی و پیش‌بینی می‌تواند مورد استفاده قرار گیرد. این معیار به ما کمک می‌کند تا ببینیم پیش‌بینی‌هایمان چه میزان با مقادیر واقعی تفاوت دارند (ماکریداکیس، اسپیلیوتیس و ماکریداکیس^۲، ۲۰۲۰) که طبق رابطه ۱۶ محاسبه می‌شود.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100 \quad \text{رابطه ۱۶}$$

A_i مقدار واقعی (مشاهده شده) در دوره i ، F_i مقدار پیش‌بینی شده در دوره i و n تعداد کل مشاهدات است.

درصد خطای مطلق میانگین متقارن^۳

یک معیار ارزیابی دقت پیش‌بینی‌ها است که مشابه درصد خطای مطلق میانگین است؛ اما به گونه‌ای طراحی شده است که نقص‌های درصد خطای مطلق میانگین را کاهش دهد و به تحلیلی دقیق‌تر منجر شود. این معیار، درصد خطای مطلق میانگین به صورت متقارن را بررسی می‌کند و به گونه‌ای طراحی شده است که به مقادیر نزدیک به صفر حساسیت کمتری داشته باشد که به صورت رابطه ۱۷ محاسبه می‌شود (هایندمن و کوهرلر^۴، ۲۰۰۶).

$$SMAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|A_i - F_i|}{\frac{|A_i| + |F_i|}{2}} \quad \text{رابطه ۱۷}$$

A_i مقدار واقعی (مشاهده شده) در دوره i ، F_i مقدار پیش‌بینی شده در دوره i و n تعداد کل مشاهدات است.

خطای پیش‌بینی^۵

خطای پیش‌بینی یک معیار ارزیابی دقت پیش‌بینی است که به سنجش تمایل یک مدل به پیش‌بینی به طور سیستماتیک بالاتر یا پایین‌تر از مقادیر واقعی می‌پردازد. به عبارت دیگر، بایاس نشان‌دهنده این است که آیا پیش‌بینی‌ها به طور متوسط بالاتر یا پایین‌تر از مقادیر واقعی هستند. خطای پیش‌بینی به شکل رابطه ۱۸ تعریف می‌شود (هایندمن و کوهرلر، ۲۰۰۶):

1. Mean Absolute Percentage Error (MAPE)
2. Makridakis, Spiliotis & Makridakis
3. Symmetric Mean Absolute Percentage Error (SMAPE)
4. Hyndman & Koehler
5. Bias

$$Bias = \frac{1}{n} \sum_{i=1}^n (F_i - A_i) \quad \text{رابطه ۱۸}$$

A_i مقدار واقعی (مشاهده شده) در دوره i ، F_i مقدار پیش‌بینی شده در دوره i و n تعداد کل مشاهدات است.

۱ AUC-ROC

یک معیار ارزیابی مدل‌های طبقه‌بندی است که به‌ویژه در مسائل طبقه‌بندی دو کلاسه^۲ استفاده می‌شود. این معیار به ما کمک می‌کند تا توانایی مدل در تفکیک بین دو کلاس مثبت و منفی را ارزیابی کنیم. **منحنی ROC**: این منحنی نمایشی از نرخ‌های مثبت واقعی^۳ در برابر نرخ‌های مثبت کاذب^۴ برای تمامی آستانه‌های ممکن پیش‌بینی است. نرخ‌های مثبت واقعی همچنین به‌عنوان حساسیت نامیده می‌شود و به‌صورت رابطه^{۱۹} تعریف می‌شود (فاوست^۵، ۲۰۰۶):

$$TPR = \frac{TP}{TP + FN} \quad \text{رابطه ۱۹}$$

TP تعداد نمونه‌های مثبت درست و FN تعداد نمونه‌های مثبت نادرست است.

AUC: مساحت زیر منحنی (AUC) ROC مقداری بین ۰ و ۱ است که نشان‌دهنده موفقیت مدل در تفکیک کلاس‌ها است. AUC برابر با ۱ نشان‌دهنده یک مدل کاملاً عالی است که قادر به تفکیک کامل دو کلاس است، در حالی که AUC برابر با ۰/۵ نشان‌دهنده یک مدل تصادفی است که نمی‌تواند کلاس‌ها را تفکیک کند و به‌صورت رابطه^{۲۰} تعریف می‌شود:

$$FPR = \frac{FP}{FP + TN} \quad \text{رابطه ۲۰}$$

FP تعداد نمونه‌های منفی نادرست و TN تعداد نمونه‌های منفی درست است.

۶ Log - Loss

معیار ارزیابی دقت برای مدل‌های طبقه‌بندی است که به‌ویژه در مسائل طبقه‌بندی دو کلاسه و چند کلاسه استفاده می‌شود. این معیار به‌طور خاص برای مدل‌هایی که احتمال‌ها را به‌عنوان خروجی تولید می‌کنند، مناسب است. این معیار می‌تواند به‌عنوان یک تابع هزینه برای بهینه‌سازی مدل‌های یادگیری ماشین به کار رود که به‌صورت رابطه^{۲۱} تعریف می‌شود (مورفی^۷، ۲۰۱۲).

1. Area Under the Receiver Operating Characteristic Curve (AUC-ROC)
2. binary classification
3. True Positive Rate
4. False Positive Rate
5. Fawcett
6. Cross-Entropy Loss
7. Murphy

$$\text{Log - Loss} = \frac{1}{n} \sum_{i=1}^n (y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i)) \quad \text{رابطه ۲۱}$$

n تعداد نمونه‌ها، y_i مقدار واقعی (برچسب) برای نمونه i و p_i احتمال پیش‌بینی شده برای کلاس مثبت (کلاس ۱) برای نمونه i است.

دقت پیش‌بینی^۱

معیار Accury یا «دقت» یکی از معیارهای اصلی ارزیابی عملکرد مدل‌های یادگیری ماشین و هوش مصنوعی است. این معیار به ما می‌گوید که چه درصدی از پیش‌بینی‌ها درست بوده‌اند. دقت به ویژه در مسائل طبقه‌بندی کاربرد دارد و به صورت رابطه ۲۲ محاسبه می‌شود (دیویس و گودریچ^۲، ۲۰۰۶):

$$\text{Accuracy} = \frac{\text{Number of Correct Predictions}}{\text{Total Number of Predictions}} \quad \text{رابطه ۲۲}$$

یافته‌های پژوهش

با توجه به چالش‌های مطرح شده در مطالعات تطبیقی بین‌المللی مالی و اهمیت مدیریت داده‌های پرت در تحلیل‌های مالی، روش‌های متعددی برای بهبود کیفیت داده‌ها در این پژوهش به کار گرفته شده است. ابتدا، برای غلبه بر تفاوت واحدهای پولی، از مفهوم آربیتراژ استفاده شده تا واحدهای مختلف به یک واحد مشترک تبدیل شوند. سپس، داده‌ها با استفاده از تکنیک نرمال‌سازی مقیاس بندی حداقلی - حداکثری به بازه $[0, 1]$ تبدیل شده‌اند تا حساسیت مدل‌های هوش مصنوعی به مقیاس ویژگی‌ها کاهش یابد. در ادامه به منظور تکمیل فرایند حذف داده‌های پرت از روش Z-score استفاده شد. در این روش داده‌های خارج از محدوده معمول را شناسایی شد و بر اساس معیارهای آماری، آن‌ها را حذف یا شدند. با اعمال این روش‌ها، اطمینان حاصل شد که داده‌های پرت که می‌توانند نتایج تحلیل را تحت تأثیر قرار دهند، به درستی مدیریت شده است و این امر به افزایش اعتبار و دقت نتایج پژوهش کمک خواهد کرد. بدین ترتیب، نتایج مربوط به آمار توصیفی به شرح جدول ۳ است.

نتایج جدول ۳ نشان می‌دهد تفاوت‌های قابل توجهی در عملکرد و ویژگی‌های صندوق‌های سرمایه‌گذاری مشترک در کشورهای توسعه‌یافته و در حال توسعه وجود دارد. بنابراین، این تفاوت‌ها می‌تواند تأثیر مستقیمی بر پیش‌بینی بازده آن‌ها در آینده داشته باشد. بدین ترتیب، در کشورهای توسعه‌یافته، صندوق‌های سرمایه‌گذاری با میانگین بازده $0/50084$ و میانگین بازده ماهانه $0/41209$ ، عملکرد نسبتاً قوی‌تری را نسبت به کشورهای در حال توسعه نشان می‌دهند. این امر نشان‌دهنده توانایی بیشتر این صندوق‌ها در ایجاد ارزش برای سرمایه‌گذاران است. بازده بازار در کشورهای توسعه‌یافته $(0/53749)$ نیز بالاتر است که می‌تواند نشان‌دهنده شرایط اقتصادی مساعدتر باشد.

1. Accury

2. Davis & Goadrich

جدول ۳. آمار توصیفی پژوهش

متغیرهای تحقیق	میانگین	حداقل	حداکثر	انحراف معیار	چولگی	آزمون شاپیر و ویلک
کشورهای توسعه یافته						
بازده صندوق	۰/۵۰۰۸۴	۰	۱	۰/۲۱۸۱۳	-۰/۱۲۲۴۵	۰/۶۴۱۰۳۷
میانگین بازده ماهانه	۰/۴۱۲۰۹	۰	۱	۰/۱۸۹۴۹	۰/۱۹۵۲۰	۰/۶۲۳۵۹
بازده بازار	۰/۵۳۷۴۹	۰	۱	۰/۱۹۳۰۷	-۰/۱۴۹۸۲	۰/۸۸۹۶۸
رشد ارزش	۰/۴۶۵۸۸	۰	۱	۰/۲۱۰۴۷	۰/۰۲۸۳۱	۰/۵۹۶۷۷
نسبت دوره برتر	۰/۵۰۲۳۱	۰	۱	۰/۳۳۳۳۶	-۰/۰۰۹۰۸	۰/۰۰۰۰۴۵
معیار بازده تفاضلی جنسن	۰/۴۹۳۸۸	۰	۱	۰/۲۰۰۵۶	-۰/۰۵۲۰۱	۰/۹۶۵۵۴
خبرگی مدیریت صندوق	۰/۵۰۲۹۰	۰	۱	۰/۲۰۲۴۸	۰/۰۹۷۶۲	۰/۷۱۲۷۷
اندازه صندوق سرمایه‌گذاری	۰/۵۶۲۴۷	۰	۱	۰/۲۰۵۳۴	۰/۰۳۷۶۳	۰/۲۴۴۵۰
درصد سرمایه‌گذاران حقیقی	۰/۴۷۶۳۹	۰	۱	۰/۲۹۳۵۸	۰/۰۴۵۴۵	۰/۰۰۰۰۶۸
درصد دارایی‌های نقدی	۰/۴۸۷۴۸	۰	۱	۰/۲۹۶۳۴	۰/۰۱۳۰۰	۰/۰۰۰۰۵۰
نسبت شارپ	۰/۴۹۷۶۵	۰	۱	۰/۱۷۲۳۴	-۰/۰۲۹۶۰	۰/۹۹۷۲۶
نسبت ترینر	۰/۴۵۰۰۰	۰	۱	۰/۱۹۷۲۲	۰/۰۲۳۳۹	۰/۷۶۸۱۹
تورم	۰/۵۴۷۳۹	۰	۱	۰/۲۱۵۲۵	-۰/۰۲۰۷۰۶	۰/۲۶۷۲۶
نرخ ارز	۰/۵۵۲۷۹	۰	۱	۰/۲۲۷۴۸	-۰/۰۲۳۱۵۰	۰/۳۲۳۲۰
عمر صندوق	۰/۴۸۹۳۲	۰	۱	۰/۱۱۲۳۵	-۰/۰۳۰۰۲۱	۰/۶۳۹۸۳
نرخ بهره واقعی	۰/۴۸۱۶۰	۰	۱	۰/۱۹۶۵۸	-۰/۰۲۴۵۳	۰/۷۷۰۴۴
تولید ناخالص داخلی	۰/۴۷۱۷۲	۰	۱	۰/۲۰۱۹۱	۰/۰۴۷۹۰۷	۰/۰۶۹۹۳
کشورهای در حال توسعه						
میانگین بازده ماهانه	۰/۵۳۳۶۵	۰	۱	۰/۲۰۳۰۰	۰/۰۶۰۴۹	۰/۹۴۳۴۹
بازده صندوق	۰/۳۶۷۵۰	۰	۱	۰/۱۸۲۶۴	۰/۶۳۸۷۹	۰/۰۳۶۹۱۰
بازده بازار	۰/۴۶۳۵۰	۰	۱	۰/۲۳۴۵۶	۰/۳۳۴۸۱	۰/۰۶۵۱۲
رشد ارزش	۰/۴۸۲۳۳	۰	۱	۰/۲۰۶۲۱	-۰/۰۳۱۱۶	۰/۰۹۵۱۱
نسبت دوره برتر	۰/۴۸۱۴۴	۰	۱	۰/۲۹۴۸۲	-۰/۰۹۰۶۰	۰/۰۰۰۰۴۶
معیار بازده تفاضلی جنسن	۰/۵۵۲۵۳	۰	۱	۰/۱۷۹۹۰	-۰/۰۱۸۷۱۷	۰/۹۶۰۸۸
خبرگی مدیریت صندوق	۰/۵۴۵۸۲	۰	۱	۰/۲۰۴۱۱	-۰/۰۱۵۰۶۱	۰/۸۲۶۷۸
عمر صندوق	۰/۴۹۶۳۲	۰	۱	۰/۱۵۹۳۱	-۰/۰۹۳۲۱	۰/۲۸۹۳۱
اندازه صندوق سرمایه‌گذاری	۰/۴۶۲۸۸	۰	۱	۰/۲۱۵۹۴	-۰/۰۳۰۹۹	۰/۲۶۳۵۷
درصد سرمایه‌گذاران حقیقی	۰/۴۶۸۰۵	۰	۱	۰/۲۸۶۲۴	۰/۱۲۹۸۷	۰/۰۰۰۵۷۲
درصد دارایی‌های نقدی	۰/۵۱۵۷۵	۰	۱	۰/۲۹۶۸۷	-۰/۰۱۲۲۷۵	۰/۰۰۰۰۶۲۳
نسبت شارپ	۰/۴۷۶۷۵	۰	۱	۰/۲۳۳۷۷	۰/۲۹۰۶۶	۰/۲۴۹۶۶
نسبت ترینر	۰/۴۳۲۲۷	۰	۱	۰/۲۰۰۸۹	۰/۳۴۳۴۰	۰/۱۳۶۸۲
تورم	۰/۴۸۳۸۳	۰	۱	۰/۱۷۶۸۱	۰/۳۱۱۰۰	۰/۷۷۳۳۲
نرخ ارز	۰/۴۸۳۸۳	۰	۱	۰/۲۳۳۹۲	-۰/۰۴۹۳۰	۰/۶۲۳۶۹
نرخ بهره واقعی	۰/۴۰۱۶۲	۰	۱	۰/۱۶۷۱۵	۰/۱۹۹۷۳	۰/۴۳۷۰۸
تولید ناخالص داخلی	۰/۵۷۴۷۹	۰	۱	۰/۲۰۷۰۵	-۰/۰۴۷۶۳۸	۰/۰۲۳۶۵

منبع: محاسبات پژوهش

از سویی دیگر، رشد ارزش در کشورهای توسعه‌یافته (۰/۴۶۵۸۸) نسبت به کشورهای در حال توسعه (۰/۴۸۲۳۳) کمتر است، اما این تفاوت چندان قابل توجه نیست. نسبت دوره برتر در کشورهای توسعه‌یافته (۰/۵۰۲۳۱) بالاتر است که نشان می‌دهد این صندوق‌ها توانسته‌اند در دوره‌های بیشتری عملکرد بهتری نسبت به شاخص داشته باشند. از طرفی دیگر، خبرگی مدیریت صندوق در کشورهای توسعه‌یافته (۰/۵۰۲۹۰) کمتر از کشورهای در حال توسعه (۰/۵۴۵۸۲) است که نشان‌دهنده رقابت شدیدتر و استانداردهای بالاتر در بازارهای توسعه‌یافته است. اندازه صندوق سرمایه‌گذاری در کشورهای توسعه‌یافته (۰/۵۶۲۴۷) بزرگ‌تر است که به مدیریت بهتر هزینه‌ها و تنوع‌بخشی بیشتر منجر می‌شود. درصد سرمایه‌گذاران حقیقی در کشورهای توسعه‌یافته (۰/۴۷۶۳۹) تقریباً مشابه کشورهای در حال توسعه (۰/۴۶۸۰۵) است. درصد دارایی‌های نقدی در کشورهای توسعه‌یافته (۰/۴۸۷۴۸) کمتر از کشورهای در حال توسعه (۰/۵۱۵۷۵) است که نشان‌دهنده استراتژی‌های سرمایه‌گذاری متفاوت است. از طرفی نسبت شارپ در کشورهای توسعه‌یافته (۰/۴۹۷۶۵) بالاتر است که نشان می‌دهد این صندوق‌ها بازده بیشتری نسبت به ریسک پذیرفته شده ایجاد کرده‌اند. نسبت ترینر نیز در کشورهای توسعه‌یافته (۰/۴۵۰۰۰) بالاتر است که عملکرد بهتر نسبت به ریسک سیستماتیک را نشان می‌دهد.

متغیرهای اقتصاد کلان مانند تورم، نرخ ارز، نرخ بهره واقعی و تولید ناخالص داخلی در دو گروه کشورها تفاوت‌های قابل توجهی بر عملکرد صندوق‌ها دارد. به نوعی که تورم در کشورهای توسعه‌یافته (۰/۵۴۷۳۹) بالاتر از کشورهای در حال توسعه (۰/۴۸۲۳۳) است که نشان‌دهنده فشارهای تورمی بیشتر در اقتصادهای پیشرفته است. نرخ ارز در کشورهای توسعه‌یافته (۰/۵۵۲۷۹) نیز بالاتر است که بر جذابیت سرمایه‌گذاری خارجی تأثیر می‌گذارد. یا نرخ بهره واقعی در کشورهای توسعه‌یافته (۰/۴۸۱۶۰) بالاتر از کشورهای در حال توسعه (۰/۴۰۱۶۲) است که نشان‌دهنده سیاست‌های پولی متفاوت است. تولید ناخالص داخلی در کشورهای در حال توسعه (۰/۵۷۴۷۹) بالاتر از کشورهای توسعه‌یافته (۰/۴۷۱۷۲) است که نشان‌دهنده رشد سریع‌تر اقتصادی در این کشورها باشد. در مجموع، این تحلیل نشان می‌دهد که صندوق‌های سرمایه‌گذاری در کشورهای توسعه‌یافته، با توجه به بازده بالاتر (۰/۵۰۰۸۴ در مقابل ۰/۳۶۷۵۰)، اندازه بزرگ‌تر (۰/۵۶۲۴۷ در مقابل ۰/۴۶۲۸۸) و نسبت‌های عملکردی بهتر (مانند نسبت شارپ ۰/۴۹۷۶۵ در مقابل ۰/۴۷۶۷۵)، پتانسیل بیشتری برای حفظ و بهبود بازدهی خود در آینده دارند. با این حال، صندوق‌های کشورهای در حال توسعه نیز، با توجه به رشد ارزش بالاتر (۰/۴۸۲۳۳ در مقابل ۰/۴۶۵۸۸) و خبرگی مدیریتی بیشتر (۰/۵۴۵۸۲ در مقابل ۰/۵۰۲۹۰)، فرصت‌های جذابی برای سرمایه‌گذاری ارائه می‌دهند. این صندوق‌ها می‌توانند با مدیریت مؤثر ریسک‌ها و بهره‌برداری از رشد اقتصادی بالاتر (تولید ناخالص داخلی ۰/۵۷۴۷۹ در مقابل ۰/۴۷۱۷۲)، عملکرد خود را بهبود بخشند.

در ادامه پژوهش برای جلوگیری از تخمین‌های کاذب از آزمون ریشه واحد بهره برده شده است. آزمون‌های ریشه واحد برای بررسی مانایی متغیرهای سری زمانی در مدل‌های اقتصادسنجی ضروری هستند. این آزمون‌ها از بروز رگرسیون کاذب جلوگیری کرده و اعتبار نتایج تحلیل را تضمین می‌کنند. در این مطالعه، از سه آزمون مختلف ریشه واحد برای اطمینان از مانایی متغیرها استفاده شده است که نتایج آن به شرح جدول ۴ است.

جدول ۴. آزمون ریشه واحد

متغیر	نماد	آزمون دیکی فولر	آزمون فیلیپس-پرون	آزمون KPSS	مرتبۀ تفاضل
بازده صندوق	Rx	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
میانگین بازده ماهانه	M	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
بازده بازار	Rm	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
رشد ارزش	G	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
نسبت دوره برتر	B	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
معیار بازده تفاضلی جنسن	J	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
خبرگی مدیریت صندوق	E	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
عمر صندوق	L	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
اندازه صندوق سرمایه‌گذاری	A	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
درصد سرمایه‌گذاران حقیقی	I	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
درصد دارایی‌های نقدی	C	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
نسبت شارپ	S	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
نسبت ترینر	T	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
تورم	Π	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
نرخ ارز	ER	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
نرخ بهره واقعی	IR	۰/۰۱	۰/۰۱	۰/۱۰۰	۰
تولید ناخالص داخلی	GDP	۰/۰۱	۰/۰۱	۰/۱۰۰	۰

منبع: محاسبات پژوهش

نتایج جدول ۴ نشان می‌دهد که تمامی متغیرهای مورد بررسی در سطح مانا هستند. این نتیجه بر اساس سه آزمون مختلف ریشه واحد - دیکی فولر، فیلیپس - پرون و KPSS به دست آمده است. برای تمامی متغیرها، مقدار p-value در آزمون‌های دیکی فولر و فیلیپس - پرون ۰/۰۱ و نشان‌دهنده رد فرضیه صفر مبنی بر وجود ریشه واحد در سطح اطمینان ۹۹ درصد است. همچنین، نتایج آزمون KPSS با مقدار ۰/۱۰۰ برای تمامی متغیرها، فرضیه صفر مبنی بر مانایی را تأیید می‌کند. مرتبه تفاضل صفر برای همه متغیرها نشان می‌دهد که نیازی به تفاضل‌گیری برای دستیابی به مانایی نیست. این امر به معنای آن است که می‌توان بدون نگرانی از مشکلات مربوط به رگرسیون کاذب، از سطح متغیرها در مدل‌سازی استفاده کرد. بنابراین، مانایی تمامی متغیرها، از جمله متغیرهای اقتصاد کلان مانند تورم، نرخ ارز، نرخ بهره واقعی و تولید ناخالص داخلی، امکان تحلیل روابط بلندمدت بین متغیرها را فراهم می‌کند. این نتایج اعتبار مدل‌های اقتصادسنجی مورد استفاده در این پژوهش را تقویت می‌کند و امکان استنباط‌های معتبر از روابط بین متغیرها را فراهم می‌آورد.

تحلیل بازده پرتفوی‌های صندوق‌های سرمایه‌گذاری یکی از مهم‌ترین مراحل در مدیریت مالی و سرمایه‌گذاری است. در این پژوهش، ابتدا با استفاده از شبکه عصبی مخچه‌ای، شبکه عصبی مصنوعی، یادگیری عمیق، هیبرید مدل، پرسپترون چند لایه، شبکه عصبی نئوکلاسیک، رگرسیون بردار پشتیبان، ماشین بردار پشتیبان، درخت تصمیم، جنگل تصادفی، جنگل خشن تصادفی و تقویت گرادیان به پیش‌بینی بازده صندوق کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی استفاده شده است. بدین گونه که از روش‌های متنوعی برای هوش مصنوعی استفاده شده است. شبکه عصبی مصنوعی به‌عنوان یکی از پایه‌ای‌ترین روش‌ها مورد استفاده قرار گرفته است. این شبکه‌ها با استفاده از پرسپترون چند لایه پیاده‌سازی شده‌اند که شامل لایه‌های ورودی، پنهان و خروجی هستند. پارامترهای تنظیم شده برای این شبکه‌ها شامل نرخ یادگیری ۰/۰۱، تعداد ۳ لایه پنهان با ۶۴، ۳۲ و ۱۶ نورون، و تابع فعال‌سازی ReLU بوده است. از سویی دیگر، یادگیری عمیق نیز در این پژوهش مورد استفاده قرار گرفته است. شبکه‌های عصبی عمیق با ۵ لایه پنهان و استفاده از تکنیک‌های مختلف Dropout با نرخ ۰/۵ برای جلوگیری از over-fitting پیاده‌سازی شده‌اند. تعداد دوره‌های آموزش (Epochs) برای این شبکه‌ها ۱۰۰ و اندازه دسته (Batch Size) تنظیم شده است. در روش مبتنی بر درخت تصمیم با حداکثر عمق ۱۰ و حداقل تعداد نمونه‌ها برای تقسیم یک گره برابر با ۵ پیاده‌سازی شده است.

جنگل تصادفی با ۵۰۰ درخت و max_features برابر با جذر تعداد کل ویژگی‌ها استفاده شده است. جنگل خشن تصادفی نیز با ۱۰۰۰ درخت و ۱۰ نقطه برش تصادفی برای هر ویژگی پیاده‌سازی شده است. از سویی دیگر، رگرسیون بردار پشتیبان (SVR) و ماشین بردار پشتیبان (SVM) نیز در این پژوهش مورد استفاده قرار گرفته‌اند. پارامتر C برای هر دو مدل برابر با ۰/۱ تنظیم شده و از کرنل RBF با gamma برابر با 'scale' استفاده شده است. برای SVR، مقدار epsilon برابر با ۰/۱ تنظیم شده است.

در ادامه، الگوریتم تقویت گرادیان نیز در این پژوهش پیاده‌سازی شده است. این الگوریتم با ۱۰۰۰ تخمین‌زننده، نرخ یادگیری ۰/۱ و عمق حداکثر درختان برابر با ۳ تنظیم شده است. پارامتر subsample نیز برابر با ۰/۸ تنظیم شده است تا از over-fitting جلوگیری شود.

در نهایت، یک مدل هیبریدی نیز در این پژوهش مورد استفاده قرار گرفته است که ترکیبی از شبکه عصبی مصنوعی و جنگل تصادفی است. در این مدل، خروجی‌های دو مدل با وزن‌های ۰/۶ برای شبکه عصبی و ۰/۴ برای جنگل تصادفی ترکیب شده‌اند تا نتیجه نهایی حاصل شود؛ سپس با استفاده از پانل هیبرید فضایی به بررسی رابطه بین متغیرها و رابطه فضایی بین صندوق‌ها پرداخته می‌شود. در ادامه برای کاهش خطا و افزایش دقت پیش‌بینی خروجی مدل اقتصادسنجی فضایی به‌عنوان ورودی جدید به هوش مصنوعی داده می‌شود تا رویکرد ترکیبی هوش مصنوعی با اقتصادسنجی فضایی صورت بگیرد و در نهایت برای افزایش اعتبار دقت مدل و جلوگیری از کاهش شفافیت دقت مدل از آزمون اعتبارسنجی متقابل بهره برده می‌شود. بدین ترتیب نتایج مربوط به پیش‌بینی بازده صندوق کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی با استفاده از هوش مصنوعی به شرح جدول ۵ است.

جدول ۵. پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک با استفاده از هوش مصنوعی

مدل/معیار	MAE	RMSE	MSE	R ²	MAPE	SMAPE	BIAS	AUC-ROC	LOG-LOSS
کشورهای عضو فدراسیون FEAS - کشورهای توسعه یافته									
شبکه عصبی مخچه‌ای	۰/۰۱۹۰۷	۰/۰۲۶۵۴	۰/۰۰۰۷۰۴	۰/۹۷۶	۱۳/۹۷۶۸	۱۴/۴۱۹	-۰/۰۰۲۶۰	۰/۹۹۷	۰/۵۶۳
شبکه عصبی مصنوعی	۰/۳۱۳۰۴۱	۰/۰۴۱۲۷	۰/۱۷۰۳۸۵	۰/۷۸۴	۲۷۱/۴۰۷	۱۰۴/۳۹۲	۰/۰۱۸۳	۰/۶۶۸	۰/۳۱۸
یادگیری عمیق	۰/۰۴۹۵۱۹	۰/۰۶۶۱۵	۰/۰۰۴۳۷	۰/۸۵۱	۴۵/۳۱۸	۳۵/۷۲۹۸	-۰/۰۰۷۱۳	۰/۹۷۲	۰/۵۷۸
هیبرید مدل	۰/۱۰۰۲۸۹	۰/۱۲۷۱۶	۰/۰۱۶۱۷	۰/۴۵۱	۷۹/۳۱۷	۵۶/۸۳۴	۰/۰۰۱۲۰	۰/۸۷۲	۰/۷۰۳
پرسپترون چند لایه	۰/۰۱۲۹۴۲	۰/۰۱۶۳۸	۰/۰۰۰۲۶۸	۰/۹۹۰	۱۰/۰۳۷	۹/۹۹۲۲	-۰/۰۰۰۵۴۶	۰/۹۹۷	۰/۵۶۰
شبکه عصبی نئوکلاسیک	۰/۰۱۰۴۰۹	۰/۰۱۳۱۷	۰/۰۰۰۱۷۳	۰/۹۹۴	۷/۹۶۶	۸/۱۱۴۰	-۰/۰۰۰۷۸۷	۰/۹۹۹	۰/۵۵۹
رگرسیون بردار پشتیبان	۰/۰۳۱۷۲۶	۰/۰۴۴۰۵	۰/۰۰۱۹۴۰۹	۰/۹۳۴	۲۹/۱۱۷	۲۴/۵۴۶۵	-۰/۰۰۰۲۷۶	۰/۹۹۵	۰/۵۸۹
ماشین بردار پشتیبان	۰/۰۱۶۶۴۰	۰/۰۲۱۹۱	۰/۰۰۰۴۸۰	۰/۹۸۳	۱۴/۸۸۸	۱۴/۹۸۰	-۰/۰۰۰۴۶۳	۰/۹۹۸	۰/۵۶۸
درخت تصمیم	۰/۰۹۵۷۰۴	۰/۱۱۸۷۲	۰/۰۱۴۰۹۶	۰/۵۲۱	۸۰/۶۳۰	۵۴/۹۵۱	۰/۰۰۰۵۹۶	۰/۸۴۹	۰/۷۶۶
جنگل تصادفی	۰/۰۶۵۰۳۱	۰/۰۸۱۵۴	۰/۰۰۶۶۴۹۱	۰/۷۷۴	۵۵/۳۱۱	۳۸/۸۹۲	-۰/۰۰۰۸۵۶	۰/۹۵۲	۰/۶۶۳
الگوریتم جنگل خشن تصادفی	۰/۰۶۴۶۶۴	۰/۰۸۱۰۴۳	۰/۰۰۶۵۶۸	۰/۷۷۷	۵۳/۹۵۲	۳۸/۶۴۳	-۰/۰۰۰۸۳۹	۰/۹۴۸	۰/۶۶۰
تقویت گرادیان	۰/۰۴۰۲۰۶	۰/۰۴۹۶۵	۰/۰۰۲۴۶۰	۰/۹۱۶	۳۱/۹۷۰	۲۶/۹۲۶	-۰/۰۰۰۴۵۱	۰/۹۷۲	۰/۶۱۴
کشورهای عضو فدراسیون FEAS - کشورهای در حال توسعه									
شبکه عصبی مخچه‌ای	۰/۰۱۷۵۳۷	۰/۰۲۳۵۲۰	۰/۰۰۰۵۵۳	۰/۹۷۸	۲۴/۲۷۸	۱۶/۱۸۴۱	۰/۰۰۰۵۹۹	۰/۹۹۵	۰/۵۷۷
شبکه عصبی مصنوعی	۰/۲۲۳۳۱۸	۰/۲۸۷۴۹	۰/۰۸۲۶۵۲	۰/۲۰۴	۲۰۷/۸۵۴	۹۴/۷۶۳	۰/۰۱۳۹۳	۰/۷۵۹	۰/۵۲۹
یادگیری عمیق	۰/۰۳۵۶۰۰	۰/۰۴۵۶۲۰	۰/۰۰۲۰۸۱۲	۰/۹۱۹	۴۰/۰۴۷	۲۷/۲۳۸	۰/۰۰۲۳۷۹	۰/۹۸۲	۰/۵۸۲۷
هیبرید مدل	۰/۱۰۲۰۹۱	۰/۱۲۷۹۴	۰/۰۱۶۳۶۸۸	۰/۳۶۵	۱۱۳/۳۷۹۷	۵۵/۹۷۰	-۰/۰۰۰۴۲۲	۰/۸۵۳	۰/۶۷۰
پرسپترون چند لایه	۰/۰۱۲۷۷۷	۰/۰۱۵۶۰۴	۰/۰۰۰۲۴۳۴	۰/۹۹۰	۱۳/۶۶۶	۱۰/۷۶۵	۰/۰۰۰۹۱۹	۰/۹۹۴	۰/۵۷۶۱
شبکه عصبی نئوکلاسیک	۰/۰۰۹۳۳۹	۰/۰۱۲۱۹۳	۰/۰۰۰۱۴۸۶	۰/۹۹۴	۱۰/۰۳۴۸	۸/۷۲۶	۰/۰۰۰۳۹۸	۰/۹۹۶	۰/۵۷۶۲
رگرسیون بردار پشتیبان	۰/۰۳۰۳۹۷	۰/۰۴۱۷۳۴	۰/۰۰۱۷۴۱	۰/۹۳۲	۴۹/۶۶۳۳	۲۳/۸۸۱	۰/۰۰۰۶۳۶	۰/۹۹۴	۰/۶۰۱

مدل/معیار	MAE	RMSE	MSE	R^2	MAPE	SMAPE	BIAS	AUC-ROC	LOG-LOSS
ماشین بردار پشتیبان	۰/۰۱۵۸۷۸	۰/۰۲۰۵۳۳	۰/۰۰۰۴۲۱۶	۰/۹۸۳	۲۲/۱۲۴۲	۱۴/۲۱۳۸۵	۰/۰۰۰۹۴۷	۰/۹۹۶	۰/۵۸۳
درخت تصمیم	۰/۰۹۹۱۴۹۸	۰/۱۲۱۹۰	۰/۰۱۴۸۶۰	۰/۴۲۳	۱۰۶/۶۲۴۴	۵۵/۶۱۶	-۰/۰۰۱۷۱	۰/۸۰۹	۰/۷۲۷
جنگل تصادفی	۰/۰۶۴۹۱۵	۰/۰۸۰۰۷۳	۰/۰۰۶۴۱۱	۰/۷۵۱	۹۰/۷۶۴۸	۳۸/۶۳۳	۰/۰۰۱۴۶۷۴	۰/۹۵۴	۰/۶۷۸
الگوریتم جنگل خشن تصادفی	۰/۰۶۴۷۰۷	۰/۰۷۹۶۹۹	۰/۰۰۶۳۵	۰/۷۵۳	۸۹/۴۰۴۴	۳۸/۵۸۱	۰/۰۰۱۵۲۹	۰/۹۵۰	۰/۶۷۵
تقویت گرادیان	۰/۰۳۶۴۶۵	۰/۰۴۶۴۰۸	۰/۰۰۲۱۵۳۷	۰/۹۱۶	۴۶/۷۰۴۱	۲۶/۴۴۱	۰/۰۰۰۵۹۳۳	۰/۹۸۵	۰/۶۲۴

منبع: محاسبات پژوهش

جدول ارائه شده نتایج پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک را با استفاده از مدل‌های مختلف هوش مصنوعی برای کشورهای توسعه یافته و در حال توسعه نشان می‌دهد. در هر دو گروه کشورها، شبکه عصبی نئوکلاسیک بهترین عملکرد را نشان داده است. این مدل در کشورهای توسعه یافته با $MAE = 0/010409$ ، $RMSE = 0/01317$ و در کشورهای در حال توسعه با $MAE = 0/009339$ ، $RMSE = 0/012193$ و $R^2 = 0/994$ بهترین نتایج را کسب کرده است. این نشان می‌دهد که شبکه عصبی نئوکلاسیک توانایی بالایی در یادگیری الگوهای پیچیده بازده صندوق‌ها دارد. پس از شبکه عصبی نئوکلاسیک، پرسپترون چند لایه و شبکه عصبی مخچه‌ای عملکرد خوبی داشته‌اند. این مدل‌ها نیز خطای کم و دقت بالایی در پیش‌بینی‌ها نشان داده‌اند. برای مثال، پرسپترون چند لایه در کشورهای توسعه یافته $MAE = 0/012942$ و $R^2 = 0/990$ داشته است. از سویی دیگر، مدل‌های مبتنی بر درخت تصمیم از جمله درخت تصمیم ساده، جنگل تصادفی و جنگل خشن تصادفی عملکرد ضعیف‌تری نسبت به مدل‌های عصبی داشته‌اند. این امر به دلیل پیچیدگی و غیرخطی بودن رابطه بین متغیرهای ورودی و بازده صندوق‌ها است که مدل‌های درختی در یادگیری آن‌ها محدودیت دارند. از سوی دیگر، شبکه عصبی مصنوعی ساده در هر دو گروه کشورها ضعیف‌ترین عملکرد را داشته است که نشان می‌دهد ساختار ساده این مدل برای پیش‌بینی بازده صندوق‌ها کافی نیست. به‌طور کلی، مدل‌ها در کشورهای توسعه یافته عملکرد بهتری نسبت به کشورهای در حال توسعه داشته‌اند. این امر به دلیل ثبات بیشتر و پیش‌بینی‌پذیری بالاتر بازارهای توسعه یافته است. برای مثال، شبکه عصبی نئوکلاسیک در کشورهای توسعه یافته $MAPE = 7/966$ و در کشورهای در حال توسعه $MAPE = 10/0348$ داشته است. معیارهای ارزیابی مختلف مانند MAE ، $RMSE$ ، R^2 و $AUC-ROC$ همگی نتایج مشابهی را نشان می‌دهند و بر برتری مدل‌های عصبی پیشرفته تأکید دارند. بدین ترتیب، این نتایج اهمیت استفاده از مدل‌های پیشرفته هوش مصنوعی در پیش‌بینی بازده صندوق‌های سرمایه‌گذاری را نشان می‌دهد. مدل‌هایی مانند شبکه عصبی نئوکلاسیک و پرسپترون چند لایه می‌توانند با دقت بالایی بازده صندوق‌ها را در بازارهای مختلف پیش‌بینی کنند و ابزار مفیدی برای تصمیم‌گیری

سرمایه‌گذاران و مدیران صندوق‌ها است. همچنین، تفاوت در عملکرد مدل‌ها بین کشورهای توسعه یافته و در حال توسعه نشان می‌دهد که باید در استفاده از این مدل‌ها به ویژگی‌های خاص هر بازار توجه کرد.

جدول ۶ نتایج تحلیل فضایی بازده صندوق‌های سرمایه‌گذاری مشترک را در دو گروه کشورهای توسعه یافته و در حال توسعه نشان می‌دهد. این تحلیل به بررسی تأثیر متغیرهای مختلف بر بازده صندوق‌ها می‌پردازد و امکان مقایسه بین دو گروه کشورها را فراهم می‌کند.

جدول ۶. بررسی فضایی بازده صندوق‌های سرمایه‌گذاری مشترک

متغیر	نماد	کشورهای توسعه یافته			کشورهای در حال توسعه			
		تخمین	خطا	مغاداری	تخمین	خطا	مغاداری	
عرض از مبدأ	Intercept	۰/۰۵۵۰۹	۰/۰۰۶۰۹	۹/۰۳۹۹	۰/۰۰۰ ***	۰/۰۲۹۸	۳/۶۱۰۳	۰/۰۰۰۳ ***
نسبت شارپ	S	۰/۰۹۹۱۷	۰/۰۰۱۵۲	۶۵/۰۵۶۷	۰/۰۰۰ ***	۰/۰۹۲۸	۳۵/۴۶۲۸	۰/۰۰۰ ***
نسبت ترینر	T	-۰/۰۴۸۱۸	۰/۰۰۱۶۴	-۲۹/۲۳۵۹	۰/۰۰۰ ***	-۰/۰۵۸۹	-۲۲/۹۸۲۲	۰/۰۰۰ ***
معیار بازده تقاضای جنسن	J	۰/۰۸۰۹۱	۰/۰۰۱۶۲	۴۹/۸۸۸۹	۰/۰۰۰ ***	۰/۰۶۸۰	۲۵/۳۳۵۳	۰/۰۰۰ ***
نسبت دوره برتر	B	۰/۰۵۷۳۶	۰/۰۰۱۸۵	۳۰/۹۴۷۶	۰/۰۰۰ ***	۰/۰۵۰۰	۱۷/۷۷۱۴	۰/۰۰۰ ***
اندازه صندوق سرمایه‌گذاری	A	-۰/۰۰۱۰۷	۰/۰۰۰۱۵	-۶۶/۶۶۷۳	۰/۰۰۰ ***	-۰/۰۰۱۲۲	-۴۱/۸۵۹۶	۰/۰۰۰ ***
رشد ارزش	G	۰/۵۰۴۷	۰/۰۱۵۷۸	۳۱/۹۷۷۷	۰/۰۰۰ ***	۰/۴۳۸۴	۱۴/۴۶۲۸	۰/۰۰۰ ***
خبرگی مدیریت صندوق	E	۰/۰۰۴۸۵۲	۰/۰۰۰۱۷۰	۲۸/۴۸۹۶	۰/۰۰۰ ***	۰/۰۰۴۴۷	۱۳/۳۸۱۰	۰/۰۰۰ ***
میانگین بازده ماهانه	M	۰/۰۹۴۱۹	۰/۰۴۴۰۹	۲/۱۳۶۲	۰/۰۳۲۶ *	۰/۰۹۲۶	۱/۹۴۹۵	۰/۰۴۷۷*
درصد سرمایه‌گذاران حقیقی	I	۰/۰۱۱۷۸	۰/۰۰۳۷۵	۳/۱۳۵۸	۰/۰۰۱۷ **	۰/۰۳۲۹	۵/۶۵۶۶	۰/۰۰۰ ***
عمر صندوق	L	۰/۰۰۹۵۷	۰/۰۰۰۱۷	۵۶/۳۱۱۸	۰/۰۰۰ ***	۰/۰۱۵۳	۴۳/۹۹۳۸	۰/۰۰۰ ***
بازده بازار	Rm	۰/۵۲۵۶	۰/۰۲۱۸۴	۲۴/۰۵۹۸	۰/۰۰۰ ***	۰/۴۷۲۸۳	۲۰/۸۶۰۸	۰/۰۰۰ ***
درصد دارایی‌های نقدی	C	-۰/۰۹۹۲۵	۰/۰۰۹۹۱۲	-۱۰/۰۱۲۶	۰/۰۰۰ ***	-۰/۱۴۴۴	-۱۲/۴۳۹۳	۰/۰۰۰ ***
تورم	π	-۰/۲۱۸۹	۰/۰۳۷۶	-۵/۸۲۲۵	۰/۰۰۰ ***	-۰/۲۰۳۷	-۶/۲۵۹۷	۰/۰۰۰ ***
تولید ناخالص داخلی	GDP	۰/۰۰۰۱	۰/۰۰۰۱۵	۶۶/۳۶۲۸	۰/۰۰۰ ***	۰/۰۰۰۰۸۷	۳۰/۶۹۶۲	۰/۰۰۰ ***
نرخ بهره واقعی	IR	۰/۵۱۲۶۴	۰/۰۳۷۵۷	-۱۳/۶۴۲۶	۰/۰۰۰ ***	-۰/۵۱۴۹۶	-۱۱/۰۸۷۱	۰/۰۰۰ ***
نرخ ارز	ER	-۰/۰۹۵۸۳	۰/۰۰۳۷۳	-۲۵/۶۲۴۸	۰/۰۰۰ ***	-۰/۵۰۹۹	-۵۱۲/۰۲۴۷	۰/۰۰۰ ***

در مورد وابستگی فضایی، ضریب ρ (Rho) در کشورهای توسعه‌یافته -0.2974 و در کشورهای در حال توسعه -0.2317822 است. این وابستگی فضایی منفی نشان می‌دهد که عملکرد صندوق‌های سرمایه‌گذاری در یک منطقه تمایل دارد با عملکرد صندوق‌ها در مناطق مجاور رابطه معکوس داشته باشد. وابستگی فضایی منفی در عملکرد صندوق‌های سرمایه‌گذاری به این معناست که وقتی صندوق‌ها در یک منطقه خاص عملکرد خوبی دارند، صندوق‌های مناطق مجاور تمایل به عملکرد ضعیف‌تری دارند، و برعکس. این رابطه معکوس ناشی از عوامل مختلفی است. به‌عنوان مثال، جریان سرمایه ممکن است از مناطق با عملکرد ضعیف‌تر به سمت مناطقی که عملکرد بهتری دارند حرکت کند، یا رقابت برای منابع محدود و فرصت‌های سرمایه‌گذاری منجر به این الگوی معکوس می‌شود. همچنین، تفاوت‌های اقتصادی منطقه‌ای و استراتژی‌های متفاوت مدیریت صندوق‌ها می‌توانند در ایجاد این الگو نقش اساسی دارند. بدین ترتیب، مشاهده می‌شود که شدت این وابستگی فضایی منفی در هر دو گروه کشورها نسبتاً ضعیف است، اما در کشورهای توسعه‌یافته اندکی قوی‌تر است. این تفاوت اندک نشان‌دهنده یکپارچگی بیشتر بازارهای مالی در کشورهای توسعه‌یافته است که به واکنش‌های قوی‌تر و سریع‌تر به تغییرات در مناطق مجاور منجر می‌شود. از سویی دیگر، معیارهای برآزش مدل نشان می‌دهد که مدل در هر دو گروه کشورها عملکرد بسیار خوبی دارد.

R-squared در کشورهای توسعه‌یافته 0.9763742 و در کشورهای در حال توسعه 0.9261852 است که نشان می‌دهد مدل توانایی بالایی در توضیح تغییرات بازده صندوق‌ها دارد. RMSE (ریشه میانگین مربعات خطا) در کشورهای توسعه‌یافته 0.09713467 و در کشورهای در حال توسعه 0.1459233 است که نشان‌دهنده دقت بالای پیش‌بینی مدل، به‌ویژه در کشورهای در حال توسعه است. در مجموع، این نتایج نشان می‌دهد که عوامل مؤثر بر بازده صندوق‌های سرمایه‌گذاری در کشورهای توسعه‌یافته و در حال توسعه تفاوت‌های قابل توجهی دارند. این تفاوت‌ها می‌تواند ناشی از ساختارهای متفاوت بازار، سطح توسعه اقتصادی، و عوامل نهادی در این دو گروه از کشورها باشد. درک این تفاوت‌ها می‌تواند به سرمایه‌گذاران و مدیران صندوق‌ها در اتخاذ استراتژی‌های مناسب برای هر بازار کمک کند.

پس از مشخص شدن نتایج مربوط هوش مصنوعی در جدول ۵ و نتایج مدل اقتصادسنجی فضایی در جدول ۶ به پیش‌بینی نهایی مدل پژوهش بر اساس ترکیب مدل اقتصادسنجی فضایی با روش‌های هوش مصنوعی پرداخته شده است. نتایج مربوط به مدل ترکیبی برای پیش‌بینی بازده صندوق در جدول ۷ درج شده است.

جدول ۷ نتایج پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک را با استفاده از رویکرد ترکیبی هوش مصنوعی و پانل هیبرید فضایی برای کشورهای توسعه‌یافته و در حال توسعه عضو فدراسیون بورس‌های اروپایی و آسیایی نشان می‌دهد. در کشورهای توسعه‌یافته، شبکه عصبی مخچه‌ای عملکرد نسبتاً خوبی با MAE برابر 0.0399 ، RMSE برابر 0.0433 و R^2 0.978 دارد. این مدل دقت پیش‌بینی بالا و AUC-ROC عالی نشان داده است. شبکه عصبی مصنوعی عملکرد مشابهی داشته، با MAPE پایین‌تر و AUC-ROC بالاتر، اما با دقت کمتر. از سویی دیگر، یادگیری عمیق با MAE برابر 0.0251 و R^2 0.985 عملکرد بسیار خوبی داشته، اما RMSE بالاتر نشان می‌دهد که برخی خطاهای بزرگ‌تر وجود دارد. مدل هیبرید عملکرد متوسطی نشان داده با MAPE نسبتاً بالا و دقت پایین‌تر.

جدول ۷. پیش‌بینی بازده صندوق کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی با رویکرد ترکیبی هوش مصنوعی با پائل هیبرید فضایی

مدل/معیار	MAE	RMSE	MSE	R ²	MAPE	SMAPE	BIAS	ACCURY	AUC-ROC	LOG-LOSS
کشورهای توسعه یافته										
شبکه عصبی مخچه‌ای	۰/۰۳۹۹	۰/۰۴۳۳	۰/۰۰۱۸۸	۰/۹۷۸	۲/۸۲۱۴	۱/۷۶۶۵۸	۰/۰۰۹۵۱	۰/۸۷۱	۰/۹۷۴۳	۰/۰۱۷۷
شبکه عصبی مصنوعی	۰/۰۳۷۷	۰/۰۳۹۴	۰/۰۰۱۵۵	۰/۹۵۹	۲/۱۸۷۵	۱/۱۶۹۹۱	۰/۰۰۱۶۱	۰/۸۰۰	۰/۹۸۹۴	۰/۰۴۹۵
یادگیری عمیق	۰/۰۲۵۱	۰/۰۵۹۴	۰/۰۰۳۵۳	۰/۹۸۵	۲/۰۰۱۷	۲/۸۶۲۶	۰/۰۰۰۸۱۷	۰/۸۵۲	۰/۹۶۲۱	۰/۰۲۹۲
هیبرید مدل	۰/۲۹۹۰	۰/۰۵۳۸	۰/۰۰۲۸۹	۰/۹۷۸	۲/۵۶۹۹	۱/۱۴۲۴	۰/۰۰۲۵۹۱	۰/۸۰۷	۰/۹۸۱۰	۰/۰۴۹۷
پرسپترون چند لایه	۰/۰۱۷۰	۰/۰۲۱۵	۰/۰۰۰۴۶	۰/۹۷۷	۱/۸۶۹۳	۱/۲۲۹۱	۰/۰۰۰۱۱۲	۰/۸۴۳	۰/۹۶۱۴	۰/۰۲۷۹
شبکه عصبی نئوکلاسیک	۰/۰۳۱۳	۰/۰۲۱۱	۰/۰۰۰۴۴۷	۰/۹۶۱	۱/۹۴۱۷	۱/۱۶۶۴۲	۰/۰۰۷۳۸۳	۰/۸۸۳	۰/۹۶۸۳	۰/۰۱۴۵
رگرسیون بردار پشتیبان	۰/۰۲۵۸	۰/۰۵۵۶	۰/۰۰۳۰۹	۰/۹۸۴	۲/۶۶۵۲	۱/۲۶۰۷	۰/۰۰۳۴۰۹۲	۰/۸۱۰	۰/۹۵۸۴	۰/۰۱۶۵
ماشین بردار پشتیبان	۰/۰۴۸۵	۰/۰۴۷۱	۰/۰۰۲۳۲	۰/۹۵۹	۱/۷۶۸۲	۲/۹۵۷۵	۰/۰۰۰۷۶۹۹	۰/۸۸۴	۰/۹۵۰۰	۰/۰۱۰۵
درخت تصمیم	۰/۰۱۱۰	۰/۰۳۸۸	۰/۰۰۱۵۰	۰/۹۷۸	۲/۵۱۴۴	۲/۶۱۸۰	۰/۰۰۰۸۶۴۵	۰/۸۰۰۹	۰/۹۸۶۹	۰/۰۱۳۲
جنگل تصادفی	۰/۰۴۷۰	۰/۰۵۱۷	۰/۰۰۲۶۷	۰/۹۵۰	۲/۶۸۱۱	۲/۶۵۷۲	۰/۰۰۱۸۷۰۰	۰/۸۹۰	۰/۹۶۲۳	۰/۰۳۷۶
الگوریتم جنگل خشن تصادفی	۰/۰۱۹۹	۰/۰۳۵۰	۰/۰۰۱۲۲	۰/۹۶۸	۱/۷۶۴۳	۲/۷۰۰۱۵	۰/۰۰۲۰۱۰۵	۰/۸۶۵	۰/۹۶۷۱	۰/۰۱۸۳
تقویت گرادیان	۰/۰۴۸۲	۰/۰۲۶۳	۰/۰۰۰۶۹	۰/۹۶۰	۲/۵۲۰۱	۱/۳۱۹۵	۰/۰۰۰۵۹۳۷	۰/۸۴۲	۰/۹۵۸۳	۰/۰۲۶۵
کشورهای در حال توسعه										
شبکه عصبی مخچه‌ای	۰/۰۱۲۳	۰/۰۵۳۰	۰/۰۰۲۸۰	۰/۹۵۳	۲/۴۹۱۶	۱/۰۶۲۰	۰/۰۰۴۳۰۲۹	۰/۸۳۳۹	۰/۹۶۴۷	۰/۰۴۷۸
شبکه عصبی مصنوعی	۰/۰۴۱۶	۰/۰۲۱۰	۰/۰۰۰۴۴	۰/۹۷۱	۱/۶۳۲۶	۱/۳۳۴۵	۰/۰۰۵۷۴۰۲	۰/۸۸۷۲	۰/۹۷۱۰	۰/۰۱۳۳
یادگیری عمیق	۰/۰۳۶۸	۰/۰۲۰۴	۰/۰۰۰۴۲	۰/۹۸۸	۲/۹۲۰۵	۱/۷۶۰۳	۰/۰۰۹۳۶۲	۰/۸۲۳۹	۰/۹۵۲۰	۰/۰۴۱۲
هیبرید مدل	۰/۰۴۳۱	۰/۰۳۲۵	۰/۰۰۱۰۵	۰/۹۵۲	۲/۸۰۱۳	۱/۴۵۷۹	۰/۰۰۳۴۳۳۱	۰/۸۰۵۳	۰/۹۸۸۹	۰/۰۲۲۱
پرسپترون چند لایه	۰/۰۲۹۸۳	۰/۰۵۰۹	۰/۰۰۲۵۹	۰/۹۶۴	۱/۲۶۹۹	۱/۶۶۸۰	۰/۰۰۷۹۹۴۵	۰/۸۴۶۰	۰/۹۷۳۱	۰/۰۳۰۷
شبکه عصبی نئوکلاسیک	۰/۰۲۳۱	۰/۰۳۹۶	۰/۰۰۱۵۶	۰/۹۵۴	۱/۳۲۰۰	۱/۷۸۳۶	۰/۰۰۵۶۴۶۷	۰/۸۱۸۰	۰/۹۵۶۷	۰/۰۲۶۸
رگرسیون بردار پشتیبان	۰/۰۱۷۲	۰/۰۵۴۶	۰/۰۰۲۹۸	۰/۹۵۰	۲/۷۰۰۰	۲/۷۲۰۳	۰/۰۰۲۷۵۵	۰/۸۴۴۱	۰/۹۸۰۰	۰/۰۴۷۳
ماشین بردار پشتیبان	۰/۰۲۰۷	۰/۰۲۵۲	۰/۰۰۰۶۳	۰/۹۸۲	۱/۴۶۱۳	۱/۰۲۶۸	۰/۰۰۹۱۰۵۹	۰/۸۹۹۸	۰/۹۵۳۴	۰/۰۱۴۳
درخت تصمیم	۰/۰۲۵۴	۰/۰۵۲۷	۰/۰۰۲۷۸	۰/۹۶۱	۲/۸۰۷۵	۰/۱۷۴۰۱	۰/۰۰۰۷۸۶۶	۰/۸۳۱۶	۰/۹۶۱۷	۰/۰۲۶۴

مدل/معیار	MAE	RMSE	MSE	R ^۲	MAPE	SMAPE	BIAS	ACCURY	AUC-ROC	LOG-LOSS
جنگل تصادفی	۰/۰۲۰۱	۰/۰۲۲۶	۰/۰۰۰۵۱۱	۰/۹۸۱	۲/۸۰۶۴	۱/۱۱۱۸	-۰/۰۰۵۲۱۹۸	۰/۸۱۶۵	۰/۹۷۱۹	۰/۰۳۷۲
الگوریتم جنگل خشن تصادفی	۰/۰۱۶۰	۰/۰۲۱۷	۰/۰۰۰۴۷۳	۰/۹۶۷	۱/۷۳۹۳	۱/۵۸۶۰	-۰/۰۰۶۶۷۲	۰/۸۲۵۶	۰/۹۸۵۱	۰/۰۲۰۵
تقویت گرادیان	۰/۰۳۸۹	۰/۰۲۲۳	۰/۰۰۰۵۰۱	۰/۹۶۱	۲/۴۰۱۳	۲/۹۲۶۹	-۰/۰۰۸۷۱۴۹	۰/۸۰۶۲	۰/۹۸۶۲	۰/۰۴۵۸

منبع: محاسبات پژوهش

پرسپترون چند لایه یکی از بهترین عملکردها را با MAE برابر با ۰/۰۱۷۴، RMSE برابر با ۰/۰۲۱۵ و R^۲ برابر با ۰/۹۷۷ دارد. شبکه عصبی نئوکلاسیک عملکرد خوبی نشان داده و بالاترین دقت را در بین همه مدل‌ها دارد. رگرسیون بردار پشتیبان عملکرد خوبی داشته، اما RMSE بالاتر نشان‌دهنده برخی خطاهای بزرگ است. ماشین بردار پشتیبان عملکرد متوسطی نشان داده و پایین‌ترین MAPE را دارد. درخت تصمیم عملکرد خوبی با MAE پایین و R^۲ بالا داشته است. جنگل تصادفی عملکرد متوسطی نشان داده اما دقت بالایی دارد. جنگل خشن تصادفی عملکرد خوبی با MAPE پایین داشته است. تقویت گرادیان عملکرد متوسطی نشان داده است.

در کشورهای در حال توسعه، شبکه عصبی مخچه‌ای عملکرد متوسطی با MAPE نسبتاً بالا داشته است. شبکه عصبی مصنوعی عملکرد خوبی با MAPE پایین و دقت بالا نشان داده است. یادگیری عمیق یکی از بهترین عملکردها را با R^۲ بالای ۰/۹۸۸ داشته، اما MAPE بالاتر نقطه ضعف آن است. مدل هیبرید عملکرد متوسطی با AUC-ROC بالا نشان داده است. پرسپترون چند لایه عملکرد خوبی با MAPE پایین داشته است. شبکه عصبی نئوکلاسیک عملکرد متوسطی با MAPE پایین نشان داده است. رگرسیون بردار پشتیبان عملکرد متوسطی با AUC-ROC بالا داشته است. ماشین بردار پشتیبان یکی از بهترین عملکردها را با بالاترین دقت نشان داده است. درخت تصمیم عملکرد متوسطی داشته است. جنگل تصادفی عملکرد خوبی با R^۲ بالا نشان داده، اما MAPE بالا نقطه ضعف آن است. جنگل خشن تصادفی یکی از بهترین عملکردها را با MAE و RMSE پایین و AUC-ROC بالا داشته است. تقویت گرادیان عملکرد متوسطی با AUC-ROC بالا نشان داده است.

در مقایسه بین دو گروه کشورها، در کشورهای توسعه یافته، پرسپترون چند لایه و درخت تصمیم بهترین عملکرد را داشته‌اند، در حالی که در کشورهای در حال توسعه، یادگیری عمیق و ماشین بردار پشتیبان برتری نشان داده‌اند. به‌طور کلی، مدل‌ها در کشورهای توسعه یافته R^۲ بالاتری نسبت به کشورهای در حال توسعه داشته‌اند که نشان‌دهنده پیش‌بینی‌پذیری بیشتر بازارهای توسعه یافته است. MAPE در کشورهای در حال توسعه برای اکثر مدل‌ها پایین‌تر است که می‌تواند به دلیل تغییرات کمتر در بازده صندوق‌های این کشورها باشد. دقت پیش‌بینی در کشورهای در حال توسعه برای اکثر مدل‌ها بالاتر است که نشان می‌دهد مدل‌ها در تشخیص جهت حرکت بازده در این بازارها موفق‌تر بوده‌اند. AUC-ROC برای اکثر مدل‌ها در هر دو گروه کشورها بسیار بالا است که نشان‌دهنده توانایی خوب مدل‌ها در تمایز

بین کلاس‌های مختلف است. Log-Loss در کشورهای توسعه یافته برای اکثر مدل‌ها پایین‌تر است که نشان می‌دهد مدل‌ها در این بازارها اطمینان بیشتری به پیش‌بینی‌های خود دارند. در مجموع، این نتایج نشان می‌دهد که استفاده از رویکرد ترکیبی هوش مصنوعی با پانل هیبرید فضایی می‌تواند به‌طور قابل توجهی دقت پیش‌بینی بازده صندوق‌های سرمایه‌گذاری را در هر دو گروه کشورها بهبود بخشد. با این حال، تفاوت‌های قابل توجهی در عملکرد مدل‌ها بین دو گروه کشورها وجود دارد که نشان می‌دهد باید در انتخاب و تنظیم مدل‌ها برای هر بازار خاص دقت کرد.

نتایج پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک با استفاده از رویکرد ترکیبی هوش مصنوعی و پانل هیبرید فضایی نشان می‌دهد که عملکرد مدل‌ها در کشورهای توسعه یافته و در حال توسعه متفاوت است. در کشورهای توسعه یافته، پرسپترون چند لایه و درخت تصمیم بهترین عملکرد را داشته‌اند، در حالی که در کشورهای در حال توسعه، یادگیری عمیق و ماشین بردار پشتیبان برتری نشان داده‌اند. به‌طور کلی، مدل‌ها در کشورهای توسعه یافته R^2 بالاتری داشته‌اند که نشان‌دهنده پیش‌بینی‌پذیری بیشتر بازارهای توسعه یافته است. از سوی دیگر، MAPE در کشورهای در حال توسعه برای اکثر مدل‌ها پایین‌تر بوده و دقت پیش‌بینی در این کشورها بالاتر است. این نتایج نشان می‌دهد که استفاده از رویکرد ترکیبی هوش مصنوعی با پانل هیبرید فضایی می‌تواند به‌طور قابل توجهی دقت پیش‌بینی بازده صندوق‌های سرمایه‌گذاری را در هر دو گروه کشورها بهبود بخشد. با این حال، تفاوت‌های قابل توجهی در عملکرد مدل‌ها بین دو گروه کشورها وجود دارد که نشان می‌دهد باید در انتخاب و تنظیم مدل‌ها برای هر بازار خاص دقت کرد.

AUC-ROC بالا در هر دو گروه کشورها نشان‌دهنده توانایی خوب مدل‌ها در تمایز بین کلاس‌های مختلف است، در حالی که Log-Loss پایین‌تر در کشورهای توسعه یافته نشان می‌دهد که مدل‌ها در این بازارها اطمینان بیشتری به پیش‌بینی‌های خود دارند. بدین ترتیب، این جمع‌بندی نشان می‌دهد که رویکرد ترکیبی هوش مصنوعی و پانل هیبرید فضایی یک روش قدرتمند برای پیش‌بینی بازده صندوق‌های سرمایه‌گذاری است. با این حال، عملکرد مدل‌ها، به شرایط بازار و سطح توسعه‌یافتگی کشورها به‌شدت وابسته است. این امر اهمیت تنظیم و انتخاب دقیق مدل‌ها برای هر بازار خاص را برجسته می‌کند. همچنین، تفاوت در عملکرد مدل‌ها بین کشورهای توسعه یافته و در حال توسعه می‌تواند ناشی از تفاوت در ساختار بازار، نقدینگی، و سایر عوامل اقتصادی باشد. این یافته‌ها می‌تواند به سرمایه‌گذاران و مدیران صندوق‌ها کمک کند تا استراتژی‌های پیش‌بینی و سرمایه‌گذاری خود را بر اساس شرایط خاص هر بازار تنظیم کنند. نتایج آن به شرح جدول ۸ است.

جدول ۸ نتایج آزمون اعتبارسنجی متقابل را برای ۱۲ مدل مختلف هوش مصنوعی نشان می‌دهد. این آزمون با دو روش اعتبارسنجی متقابل و تقسیم‌بندی آموزش - آزمون انجام شده است. نتایج نشان می‌دهد که عملکرد تمام مدل‌ها بسیار مشابه و قوی است. در روش اعتبارسنجی متقابل، تمام مدل‌ها دقیقاً نتایج یکسانی را نشان می‌دهند MAE برابر با ۰/۰۷۹، RMSE برابر با ۰/۰۹۹، MSE برابر با ۰/۰۰۹۹، R^2 برابر با ۰/۹۹۹، MAPE برابر با ۱۱/۰۵ درصد، SMAPE برابر با ۶/۴۷۳ Bias برابر با ۰/۰۰۰، Variance برابر با ۰/۰۰۹۹ و Accuracy برابر با ۰/۸۸۹. این نتایج حاکی از عملکرد بسیار خوب و پایدار مدل‌ها در پیش‌بینی بازده صندوق‌ها است.

جدول ۸. آزمون اعتبار سنجی متقابل

مدل	روش اعتبارسنجی	MAE	RMSE	MSE	R ²	MAPE	SMAPE	Bias	Variance	Accury
شبکه عصبی مخچه‌ای	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
شبکه عصبی مخچه‌ای	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۳/۷۰	۶/۰۹۷	۰/۰۰۰۳	۰/۰۰۹۹	۰/۸۹۴
شبکه عصبی مصنوعی	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
شبکه عصبی مصنوعی	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
یادگیری عمیق	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
یادگیری عمیق	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
هیبرید مدل	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
هیبرید مدل	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
پرسترون چند لایه	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
پرسترون چند لایه	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
شبکه عصبی نئوکلاسیک	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
شبکه عصبی نئوکلاسیک	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
رگرسیون بردار پشتیبان	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
رگرسیون بردار پشتیبان	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
ماشین بردار پشتیبان	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
ماشین بردار پشتیبان	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
درخت تصمیم	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
درخت تصمیم	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
جنگل تصادفی	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
جنگل تصادفی	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
جنگل خشن تصادفی	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹

مدل	روش اعتبارسنجی	MAE	RMSE	MSE	R ^۲	MAPE	SMAPE	Bias	Variance	Accury
جنگل خشن تصادفی	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	-۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
تقویت‌گرادیان	اعتبارسنجی متقابل	۰/۰۷۹۸	۰/۰۹۹۹	۰/۰۰۹۹	۰/۹۹۹۷	۱۱/۰۵	۶/۴۷۳	-۰/۰۰۰۰	۰/۰۰۹۹	۰/۸۸۹
تقویت‌گرادیان	تقسیم‌بندی آموزش - آزمون	۰/۰۷۹۳	۰/۰۹۹۴	۰/۰۰۹۹	۰/۹۹۹۷	۱۳/۷۰	۶/۰۹۷	-۰/۰۰۰۳	۰/۰۰۹۹	۰/۸۹۴

منبع: محاسبات پژوهش

در روش تقسیم‌بندی آموزش - آزمون، اکثر مدل‌ها نتایج مشابهی دارند با MAE برابر ۰/۰۷۹۳، RMSE برابر با ۰/۰۹۹۴ و سایر معیارها مشابه روش اعتبارسنجی متقابل. تنها استثنا مدل‌های شبکه عصبی مخچه‌ای و تقویت‌گرادیان هستند که MAPE بالاتری (۱۳/۷۰ درصد) و SMAPE پایین‌تری (۶/۰۹۷) نشان می‌دهند.

این نتایج نشان می‌دهد که مدل‌ها از نظر پایداری و قابلیت تعمیم بسیار خوب عمل می‌کنند. R^۲ بسیار بالا (۰/۹۹۹۷) نشان‌دهنده توانایی عالی مدل‌ها در توضیح واریانس داده‌ها و MAPE نسبتاً پایین و Accuracy بالا نیز گویای دقت خوب پیش‌بینی‌هاست. Bias نزدیک به صفر نشان می‌دهد که مدل‌ها تمایل به کم‌برآورد یا بیش‌برآورد ندارند.

نتیجه‌گیری و پیشنهادها

این پژوهش با هدف پیش‌بینی بازده صندوق‌های سرمایه‌گذاری کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی با استفاده از تکنیک‌های هوش مصنوعی انجام شده است. در این تحقیق، مدل‌های مختلفی از جمله شبکه عصبی مخچه‌ای، شبکه عصبی مصنوعی، یادگیری عمیق، هیبرید مدل، پرسپترون چند لایه، شبکه عصبی نئوکلاسیک، رگرسیون بردار پشتیبان، ماشین بردار پشتیبان، درخت تصمیم، جنگل تصادفی، جنگل خشن تصادفی و تقویت‌گرادیان مورد استفاده قرار گرفته‌اند. تحلیل نتایج این مدل‌ها عملکرد متفاوتی را در پیش‌بینی بازده صندوق‌ها در کشورهای توسعه‌یافته و در حال توسعه نشان داده است.

یافته‌های این تحقیق به وضوح نشان‌دهنده برتری مدل‌های پیشرفته هوش مصنوعی در پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک است. نتایج حائز اهمیت تأکید می‌کند که شبکه عصبی نئوکلاسیک در هر دو گروه کشورهای توسعه‌یافته و در حال توسعه، بهترین عملکرد را از نظر معیارهای ارزیابی مختلف داشته است. به‌عنوان مثال، در کشورهای توسعه‌یافته، این مدل با MAE برابر با ۰/۰۱۰۴۰۹، RMSE برابر با ۰/۰۱۳۱۷ و R^۲ برابر با ۰/۹۴۰ عمل کرده است. همچنین، در کشورهای در حال توسعه، نتایج این مدل به MAE برابر با ۰/۰۰۹۳۳۹، RMSE برابر با ۰/۰۱۲۱۹۳ و R^۲ برابر با ۰/۹۴۰ کاهش یافته است. این آمار حاکی از توانایی بالای شبکه عصبی نئوکلاسیک در یادگیری الگوهای پیچیده و غیرخطی در داده‌های مالی است. به‌علاوه، پرسپترون چند لایه نیز عملکرد چشمگیری از

خود نشان داده است؛ به طوری که در کشورهای توسعه یافته MAE برابر با ۰/۱۲۹۴۲ و R^2 برابر با ۰/۹۹۰ داشته است. در عین حال، شبکه عصبی مخچه‌ای نیز نتایج خوبی را ارائه کرده که بر قابلیت این مدل‌ها در تحلیل داده‌های مالی تأکید می‌کند. در مقابل، مدل‌های مبتنی بر درخت تصمیم به‌ویژه درخت تصمیم ساده و جنگل تصادفی، نتایج ضعیف‌تری داشتند و نتوانستند به خوبی روابط غیرخطی و پیچیده بین متغیرها را مدل‌سازی کنند. این امر تأثیر محدودیت‌های این مدل‌ها در یادگیری الگوهای پیچیده را نشان می‌دهد. علاوه بر این، شبکه عصبی مصنوعی ساده، کمترین عملکرد را در هر دو گروه کشورها از خود نشان داده است که بیانگر ناکافی بودن ساختار ساده این مدل برای پیش‌بینی کارآمد بازده صندوق‌هاست. این تحقیق همچنین تفاوت‌های چشمگیری در عملکرد مدل‌ها میان کشورهای توسعه یافته و در حال توسعه را نشان می‌دهد. برای مثال، شبکه عصبی نئوکلاسیک در کشورهای توسعه یافته با MAPE برابر با ۷/۶۶ و در کشورهای در حال توسعه با MAPE برابر با ۱۰/۳۴۸ عمل کرده است. این تفاوت‌ها به وضوح حاکی از ثبات بیشتر و پیش‌بینی‌پذیری بالاتر بازارهای توسعه یافته نسبت به بازارهای در حال توسعه است. در نهایت، این نتایج اهمیت به کارگیری مدل‌های پیشرفته هوش مصنوعی در فرایند پیش‌بینی بازده صندوق‌های سرمایه‌گذاری را نشان می‌دهد. بنابراین، سرمایه‌گذاران و مدیران صندوق‌ها باید با توجه به ویژگی‌های خاص هر بازار و عملکرد مدل‌های مختلف، استراتژی‌های خود را بهینه‌سازی کنند تا از ابزارهای مؤثری در تصمیم‌گیری‌های مالی بهره‌مند شوند. به طور کلی، این تحقیق به نقش کلیدی مدل‌های یادگیری عمیق در ارتقای دقت پیش‌بینی‌ها و بهبود تصمیم‌گیری‌های مالی تأکید دارد. این نتایج با مطالعات پیشین مطابقت دارد. برای مثال، جوزف و همکاران (۲۰۱۷) به امکان‌پذیری پیش‌بینی بازده سهام با استفاده از رویکردهای یادگیری ماشین اشاره کردند. این نتیجه با تحقیق حاضر همخوانی دارد، چرا که رویکردهای یادگیری ماشین (شبکه عصبی مصنوعی و چندلایه پرسپترون) نیز در اینجا عملکرد مناسبی در پیش‌بینی بازده داشتند. هاروی و لیو (۲۰۲۲) چارچوب جدیدی برای ارزیابی عملکرد صندوق‌ها راه‌اندازی کردند که نشان‌دهنده اهمیت ابزارهای دقیق پیش‌بینی است. تحقیق حاضر نیز اهمیت استفاده از مدل‌های پیشرفته مانند گرادیان تقویتی و رگرسیون برداری پشتیبان را تأیید می‌کند. همچنین، فیبرگ و همکاران (۲۰۲۳) اشاره کردند که تکنیک‌های یادگیری ماشین موجب بهبود پیش‌بینی بازده سهام می‌شود که مشابه با نتایج تحقیق حاضر است که نشان داد مدل‌های یادگیری ماشین بهبود قابل توجهی در پیش‌بینی بازده دارند. پیووزان و همکاران (۲۰۲۳) نیز نتیجه‌گیری کردند که مدل‌های رگرسیون و یادگیری ماشین عملکرد بهتری دارند. نتایج تحقیق حاضر که از عملکرد بهتر مدل هوش مصنوعی مانند رگرسیون بردار پشتیبان نشان می‌دهد، این نتایج را تأیید می‌کند. با این حال، نتایج تحقیق حاضر در تضاد با نتایج الشواوره (۲۰۲۴) است که مدل ARMA را برای تخمین بازده بهتر می‌دانست؛ در تحقیق حاضر مدل گرادیان تقویتی بهترین عملکرد را نشان داد. نهایتاً، ژنگ و همکاران (۲۰۲۴) به اهمیت مدیریت نوسان‌ها و زمان‌بندی بازده اشاره کردند. تحقیق حاضر نیز تأیید کرد که مدل‌های هوش مصنوعی با دقت بالا قادر به پیش‌بینی نوسان‌ها و بازده هستند. این نتایج نشان‌دهنده همگرایی پژوهش‌های مختلف در تأکید بر اهمیت استفاده از رویکرد یادگیری ماشین در پیش‌بینی بازده و مدیریت نوسان‌ها است. همچنین نتایج حاصل از ترکیب مدل‌های هوش مصنوعی و اقتصاد سنجی فضایی نیز نشان‌دهنده بهبود قابل توجه

در دقت پیش‌بینی بازده صندوق‌ها می‌باشد. تحلیل‌های انجام شده بر اساس نتایج به‌دست‌آمده از مدل‌های هوش مصنوعی و تحلیل‌های اقتصادی فضایی در مورد بازده صندوق‌های سرمایه‌گذاری کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی، گویای تفاوت‌های معناداری در تأثیر متغیرهای مختلف بر عملکرد این صندوق‌ها است. نتایج نشان می‌دهند که نسبت شارپ در هر دو گروه کشورهای توسعه‌یافته و در حال توسعه تأثیر مثبت و معناداری بر بازده صندوق‌ها دارد، به طوری که در کشورهای توسعه‌یافته و در مقابل $0/09917$ ، مقدار آن در کشورهای در حال توسعه برابر با $0/0928$ است. این تفاوت به معنای حساسیت بالاتر سرمایه‌گذاران در بازارهای پیشرفته به ریسک تعدیل شده بازده می‌باشد. در ادامه، نسبت ترینر در هر دو گروه تأثیر منفی دارد و این اثر در کشورهای در حال توسعه ($-0/0589$) به وضوح بیشتر است تا کشورهای توسعه‌یافته ($-0/04818$) که نشان‌دهنده آسیب‌پذیری بیشتر بازارهای نوظهور به ریسک سیستماتیک است. همچنین، معیار بازدهی تفاضلی جنسن در کشورهای توسعه‌یافته تأثیر مثبتی با مقدار $0/08091$ دارد که در مقایسه با $0/0680$ در کشورهای در حال توسعه قوی‌تر است. این موضوع اهمیت مهارت‌های مدیریتی در بازارهای توسعه‌یافته را به وضوح نشان می‌دهد. به علاوه، رشد ارزش نیز در هر دو گروه اثر مثبت قابل توجهی دارد، اما این تأثیر در کشورهای توسعه‌یافته ($0/5047$) بیشتر از کشورهای در حال توسعه ($0/4384$) است که نمایانگر ثبات بالاتر در رشد ارزش صندوق‌ها در بازارهای پیشرفته است. اما درصد سرمایه‌گذاران حقیقی در کشورهای در حال توسعه تأثیر مثبت بیشتری دارد ($0/0329$ در مقایسه با $0/01178$) که نشان‌دهنده نقش کلیدی سرمایه‌گذاران خرد در این بازارهاست. همچنین، بازده بازار در هر دو گروه تأثیر مثبت قوی دارد، اما در کشورهای توسعه‌یافته با مقدار $0/5256$ بیشتر از کشورهای در حال توسعه ($0/47283$) است که به هم‌بستگی بالاتر صندوق‌ها با عملکرد کلی بازار دلالت دارد. نرخ ارز نیز در کشورهای در حال توسعه تأثیر منفی شدیدتری دارد ($-0/5099$ در مقابل $-0/09583$) که نشان‌دهنده آسیب‌پذیری بیشتر این بازارها نسبت به نوسان‌های ارزی است. از سوی دیگر، تورم و نرخ بهره واقعی نیز در هر دو گروه تأثیر منفی قابل توجهی دارند که بر اهمیت ثبات اقتصاد کلان در عملکرد صندوق‌ها تأکید می‌کند. در خصوص وابستگی فضایی، نتیجه‌گیری شده که ضریب $Rho (\rho)$ در کشورهای توسعه‌یافته برابر با $-0/02974$ و در کشورهای در حال توسعه برابر با $-0/02317822$ و نشان‌دهنده وجود وابستگی فضایی منفی در عملکرد صندوق‌هاست؛ یعنی زمانی که صندوق‌ها در یک منطقه عملکرد خوبی دارند، صندوق‌های مناطق مجاور غالباً عملکرد ضعیف‌تری خواهند داشت. همچنین، براساس معیارهای برازش مدل، R -squared در کشورهای توسعه‌یافته برابر با $0/9763742$ و در کشورهای در حال توسعه برابر با $0/9261852$ است که این نشان‌دهنده توانایی بالای مدل در توضیح تغییرات بازده صندوق‌ها است. $RMSE$ نیز در کشورهای توسعه‌یافته $0/09713467$ و در کشورهای در حال توسعه $0/01459233$ به دست آمده که نشان‌دهنده دقت بالای پیش‌بینی‌های مدل، به‌ویژه در کشورهای در حال توسعه است. این تفاوت‌ها در عملکرد و تأثیر متغیرها بر بازده صندوق‌های سرمایه‌گذاری، می‌تواند ناشی از ساختارهای متفاوت بازار، سطح توسعه اقتصادی، و عوامل نهادی باشد. بر این اساس، درک این تفاوت‌ها می‌تواند به سرمایه‌گذاران و مدیران صندوق‌ها در اتخاذ استراتژی‌های مناسبی برای هر بازار کمک کند و به بهینه‌سازی تصمیمات مالی منجر شود. نتایج پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک با

استفاده از رویکرد ترکیبی هوش مصنوعی و پانل هیبرید فضایی نشان می‌دهد که عملکرد مدل‌ها در کشورهای توسعه‌یافته و در حال توسعه تفاوت‌های معناداری دارد. در کشورهای توسعه‌یافته، مدل‌هایی مانند پرسپترون چند لایه و درخت تصمیم بهترین عملکرد را داشته‌اند، در حالی که در کشورهای در حال توسعه، یادگیری عمیق و ماشین بردار پشتیبان برتری نشان داده‌اند. به‌طور کلی، مدل‌ها در کشورهای توسعه‌یافته R^2 بالاتری را نمایش می‌دهند که نشان‌دهنده پیش‌بینی‌پذیری بیشتر این بازارها است. از سوی دیگر، MAPE در کشورهای در حال توسعه برای اکثر مدل‌ها کمتر بوده و دقت پیش‌بینی در این کشورها بالاتر است. این نتایج تأکید می‌کند که استفاده از رویکرد ترکیبی هوش مصنوعی و پانل هیبرید فضایی می‌تواند دقت پیش‌بینی بازده صندوق‌ها را بهبود بخشد، اما تفاوت‌های قابل توجهی در عملکرد مدل‌ها بین دو گروه کشورها وجود دارد. در تحقیقات آتی، می‌توان دامنه بررسی را به کشورهای بیشتری از قاره‌های دیگر مانند آمریکای لاتین، آفریقا و آسیای شرقی گسترش داد تا تفاوت‌های عملکرد مدل‌ها در بازارهای مختلف بررسی شود و نتایج جهانی‌تری حاصل شود.

همچنین پیشنهاد می‌شود که تحقیق‌های آینده به تحلیل دقیق‌تر متغیرهای کلان اقتصادی و سایر عوامل مؤثر بر بازده صندوق‌های سرمایه‌گذاری بپردازند تا ساختار و مکانیسم‌های پیچیده‌تر بازار به‌طور عمیق‌تری بررسی شوند. یکی از محدودیت‌های اصلی این پژوهش، دسترسی به داده‌های کامل و جامع برای بررسی تمامی کشورهای عضو فدراسیون بورس‌های اروپایی و آسیایی است. عدم وجود داده‌های دقیق و به‌روز می‌تواند تأثیر مستقیمی بر نتایج و تجزیه و تحلیل‌ها داشته باشد. از سوی دیگر، استفاده از مدل‌های مختلف هوش مصنوعی ممکن است سبب ایجاد سردرگمی در مقایسه نتایج شود. همچنین، برخی مدل‌ها ممکن است به دلیل پیچیدگی‌های خود نیاز به زمان طولانی‌تری برای آموزش داشته باشند که این موضوع می‌تواند منجر به نیاز به منابع بیشتر شود. همچنین، تأثیر متغیرهای اقتصادی و بازار بر بازده صندوق‌ها، ممکن است تحت تأثیر عوامل غیرقابل پیش‌بینی چون بحران‌های اقتصادی و سیاسی قرار گیرد که این امر می‌تواند بر نتایج تحقیق تأثیرگذار باشد. در نهایت، گرچه این تحقیق بین کشورهای توسعه‌یافته و در حال توسعه تفاوت‌هایی را نشان می‌دهد، اما نتایج به‌دست آمده ممکن است به دلیل تنوع فرهنگی، اجتماعی و اقتصادی در سطح محلی کلی نشده و تنها در چند کشور معتبر باشد.

منابع

- اخباری، حمیدرضا؛ محمدزاده ساطع، حیدر؛ برادران حسن زاده، رسول و زینالی، مهدی (۱۴۰۳). بهینه‌سازی پیش‌بینی بازده سهام مبتنی بر ریسک در صنایع منتخب بورس اوراق بهادار تهران (رهیافت تحلیل پوششی داده‌ها). *تحقیقات مالی*، ۲۶(۲)، ۳۳۱-۳۵۴.
- توکلی، سامان و آشتاب، علی (۱۴۰۲). مقایسه کارایی مدل‌های یادگیری ماشین و مدل‌های آماری در پیش‌بینی ریسک مالی. *راهبرد مدیریت مالی*، ۱۱(۱)، ۵۳-۷۶.
- چاوشی، صابر (۱۳۹۲). پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک با رویکرد شبکه‌های عصبی مصنوعی. *مهندسی مالی و مدیریت اوراق بهادار*، ۱۷(۴)، ۱۱۷-۱۳۲.

- شریف‌فر، امیر؛ خلیلی عراقی، مریم؛ رئیسی وانانی، ایمان؛ فلاح شمس، میرفیض (۱۴۰۱). کاربرد معماری‌های یادگیری عمیق در پیش‌بینی قیمت سهام (رویکرد شبکه عصبی پیچشی CNN). *مدیریت دارایی و تأمین مالی*، ۱۰(۳)، ۲۰-۱.
- رجبی، راضیه؛ عسگری، محمدرضا و دهقان، عبدالمجید (۱۳۹۷). پیش‌بینی بازده سهام شرکت‌های پذیرفته شده در بورس و اوراق بهادار تهران با استفاده از تکنیک‌های داده‌کاوی شبکه عصبی (MLP) و مدل افزودنی کلی (GAM). *رویکردهای پژوهشی نو در علوم مدیریت*، ۴(۱۰)، ۶۱-۸۰.
- خسرویانی، مهدی؛ حیدر پور، فرزانه (۱۴۰۱). مدل‌سازی جهت پیش‌بینی ریسک نقدینگی بانک‌های دولتی ایران با استفاده از شبکه‌های عصبی مصنوعی و شاخص‌های حسابداری. *پژوهش‌های حسابداری مالی و حسابرسی*، ۱۴(۵۵)، ۱۶۳-۱۸۰.
- کشاوری حداد، غلامرضا؛ ابراهیم نژاد، علی و گروسی، مرتضی (۱۴۰۱). عملکرد سرمایه‌گذاران حقیقی و حقوقی در پیش‌بینی بازده صندوق‌های سرمایه‌گذاری مشترک. *دوفصلنامه علمی مطالعات و سیاست‌های اقتصادی*، ۹(۱)، ۹۴-۱۱۵.
- نمازی، محمد و کیامهر، محمد مهدی (۱۳۸۶). پیش‌بینی بازده روزانه سهام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی. *تحقیقات مالی*، ۹(۲۴)، ۱۱۶-۱۳۴.

References

- Abe, M. & Nakayama, H. (2018). Deep learning for forecasting stock returns in the cross-section. D. Phung, V.S. Tseng, G.I. Webb, B. Ho, M. Ganji & L. Rashidi (Eds.), *Advances in knowledge discovery and data mining*, 1(22), 273-284.
- Aggarwal, R. K. & Jorion, P. (2010). The performance of emerging hedge funds and managers. *Journal of Financial Economics*, 96(2), 238-256.
- Akhbari, H., Mohammadzadeh Salteh, H., Baradaran Hassanzadeh, R. & Zeynali, M. (2024). Optimizing Risk-based Stock Return Prediction in Tehran Stock Exchange industries: A Data Envelopment Analysis. *Financial Research Journal*, 26(2), 331-354. (in Persian)
- Al Shawawreh, F. K. (2024). Risk Modeling, Return Forecasting, and Optimal Portfolio Selection: *An Empirical Study on Amman Stock Exchange*, 39(2), 49-97.
- Alabdullah, A.A., Iqbal, M., Zahid, M., Khan, K., Amin, M.N., Jalal, F.E. (2022). Prediction of rapid chloride penetration resistance of metakaolin based high strength concrete using light GBM and XGBoost models by incorporating SHAP analysis. *Constr. Build. Mater.* 345 (128296), 2-13.
- Al-Sultan, S. Y. & Al-Baltah, I. A. (2024). An improved random forest algorithm (ERFA) utilizing an unbalanced and balanced dataset to predict customer churn in the banking sector. *IEEE Access*, 1, 99-101.
- Bali, T. G., Brown, S. J. & Caglayan, M. O. (2014). Macroeconomic risk and hedge fund returns. *Journal of Financial Economics*, 114(1), 1-19. <https://doi.org/10.1016/j.jfineco.2014.06.008>
- Ballings, M., Poel, D. V. D., Hespeels, N. & Gryp, R. (2015). Evaluating multiple classifiers for stock price direction prediction. *Expert Systems with Applications*, 42, 7046-7056.

- Bauer, M. D. & Hamilton, J. D. (2018). Robust bond risk premia. *The Review of Financial Studies*, 31(2), 399-448.
- Behera, J., Pasayat, A. K., Behera, H. & Kumar, P. (2023). Prediction based mean-value-at-risk portfolio optimization using machine learning regression algorithms for multi-national stock markets. *Engineering Applications of Artificial Intelligence*, 120 (2), 2-14.
- Ben-David, I., Franzoni, F. & Moussawi, R. (2017). Exchange-traded funds. *Annual Review of Financial Economics*, 9(1), 169-189.
- Bollen, N. P. & Busse, J. A. (2005). Short-term persistence in mutual fund performance. *The Review of Financial Studies*, 18(2), 569-597.
- Boonprasope, A. & Tippayawong, K. Y. (2024). Predicting Healthcare Mutual Fund Performance Using Deep Learning and Linear Regression. *International Journal of Financial Studies*, 12(1), 23.
- Box, G. E. & Pierce, D. A. (1970). Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. *Journal of the American statistical Association*, 65(332), 1509-1526.
- Campbell, J. Y. & Ammer, J. (1993). What moves the stock and bond markets? A variance decomposition for long-term asset returns. *The Journal of Finance*, 48(1), 3-37.
- Chavoshi, K., Saber, A. (2013). Prediction of return of mutual investment funds with the approach of artificial neural networks. *Financial Engineering and Portfolio Management*, 17(4), 117 – 131. (in Persian)
- Chen, J., Hong, H., Huang, M. & Kubik, J. D. (2004). Does fund size erode mutual fund performance? The role of liquidity and organization. *American Economic Review*, 94(5), 1276-1302.
- Chen, J., Ma, F., Qiu, X. & Li, T. (2023). The role of categorical EPU indices in predicting stock-market returns. *International Review of Economics & Finance*, 87, 365-378.
- Chen, W., Zhang, H., Mehlawat, M. K. & Jia, L. (2021). Mean-variance portfolio optimization using machine learning-based stock price prediction. *Applied Soft Computing*, 100(1), 1-18.
- Cheng, C. S. A. & Hollio, D. (2008). Do core and noncore cash flows from operation persist differentially in predicting future cash flows? *Review of Quantitative Finance and Accounting*, 31, 29-53.
- Chia, M. Y., Huang, Y. F. & Koo, C. H. (2022). Resolving data-hungry nature of machine learning reference evapotranspiration estimating models using inter-model ensembles with various data management schemes. *Agricultural Water Management*, 261, 107343.
- Choi, I. & Kim, W. C. (2024). Enhancing Exchange-Traded Fund Price Predictions: Insights from Information-Theoretic Networks and Node Embeddings. *Entropy*, 26(1), 70.
- Danil, B., Christensen, B. J., Mühlbach, N. N. & Nielsen, M. S. (2024). Targeting predictors in random forest regression. *Journal of Financial Econometrics*, 22(1), 104-128.

- Danquah, R. & Yu, B. (2023). Selection ability and market timing skills of mutual fund and unit trust managers in a developing economy: evidence from Ghana. *Business Analyst Journal*, 44(1), 1-14.
- Davis, J. & Goadrich, M. (2006). The relationship between Precision-Recall and ROC curves. *In Proceedings of the 23rd International Conference on Machine Learning (ICML)*, 2006, 233-240.
- Deng, Y., Wang, Y. & Zhou, T. (2024). Macroeconomic Expectations and Expected Returns. *Journal of Financial and Quantitative Analysis*, 1–37.
- Eling, M. & Schuhmacher, F. (2007). Does the choice of performance measure influence the evaluation of hedge funds? *Journal of Banking & Finance*, 31(9), 2632-2647.
- Fama, E. (1970) Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25: 383-417.
- Fama, E. F. & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of financial economics*, 33(1), 3-56.
- Fama, E. F. & Schwert, G. W. (1977). Asset returns and inflation. *Journal of financial economics*, 5(2), 115-146.
- Farshadfar, Z. & Prokopczuk, M. (2019). Nonlinear model improves stock return out of sample forecasting (case study: united state stock market). *International Journal of Finance & Managerial Accounting*, 3(12), 1-13.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874.
- Ferson, W. E. & Harvey, C. R. (1991). The variation of economic risk premiums. *Journal of Political Economy*, 99(2), 385-415.
- Fieberg, C., Metko, D., Poddig, T. & Loy, T. (2023). Machine learning techniques for cross-sectional equity returns' prediction. *OR Spectrum*, 45(1), 289-323.
- Gargano, A., Pettenuzzo, D. & Timmermann, A. (2019). Bond return predictability: Economic value and links to the macroeconomy. *Management Sci.*, 65(2), 508–540.
- Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning*. MIT Press.
- Grinblatt, M. & Keloharju, M. (2000). The investment behavior and performance of various investor types: a study of Finland's unique data set. *Journal of financial economics*, 55(1), 43-67.
- Gurkaynak, R.S., Sack, B. & Wright, J.H. (2007) The U.S. treasury yield curve: 1961 to the present. *J. Monetary Econom.* 54(8), 2291–2304.
- Harrison, B. & Moore, W. (2012). Forecasting stock market volatility in central and eastern European countries. *Journal of forecasting*, 31(6), 490-503.
- Harvey, C. R. & Liu, Y. (2022). Luck versus skill in the cross section of mutual fund returns: Reexamining the evidence. *The Journal of Finance*, 77(3), 1921-1966.
- Ho, W.K., Tang, B.-S., Wong, S.W. (2021). Predicting property prices with machine learning algorithms. *J. Prop. Res.*, 38 (1), 48–70.

- Hyndman, R. J. & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688.
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- Jensen, M. C. (1968). The performance of mutual funds in the period 1945–1964. *The Journal of finance*, 23(2), 389-416.
- Jorion, P. (1991). The pricing of exchange rate risk in the stock market. *Journal of financial and quantitative analysis*, 26(3), 363-376.
- Joseph, A., Larrain, M. & Turner, C. (2017). Daily stock returns characteristics and forecastability. *Procedia computer science*, 114, 481-490.
- Kacperczyk, M., Sialm, C. & Zheng, L. (2005). On the industry concentration of actively managed equity mutual funds. *The Journal of Finance*, 60(4), 1983-2011.
- Kanade, A., Sherdiwala, M. & Sherekar, S. (2022). Performance of machine learning algorithms to predict right mutual funds of Indian companies. In *Modern Approaches in Machine Learning & Cognitive Science: A Walkthrough* (pp. 21-34). Cham: Springer International Publishing.
- Keshavarz Haddad, Gh., Ebrahimnejad, A. & Grossi, M. (2022). The performance of real and legal investors in predicting the return of mutual investment funds. *Biquarterly Scientific Journal of Economic Studies and Policies*, 9(1), 94-115. (in Persian)
- Khosroyani, Mahdi & Heydarpoor, Farzaneh (2022). Modeling to Predict the Liquidity Risk of Iran's Government Banks Using Artificial Neural Networks and Accounting Indicators. *Financial Accounting and Auditing Researches*, 14(55), 163-180. (in Persian)
- LeSage, J. P. & Pace, R. K. (2009). *Introduction to Spatial Econometrics*. CRC Press.
- Levy, R. A. (1967). Random walks, *Reality or myth*. *Financial Analysts Journal*, 23(6), 69-77.
- Li, X., Qin, Zh. & Kar, S. (2010). Mean-variance skewness model for portfolio selection with fuzzy returns, *European Journal of Operational Research*, 202 (1), 239-247.
- Lin, G., Lin, A., Gu, D. (2022). Using support vector regression and K-nearest neighbors for short-term traffic flow prediction based on maximal information coefficient. *Inform. Sci.* 608, 517–531.
- Lu, C. J. & Wu, J. Y. (2011). An efficient CMAC neural network for stock index forecasting. *Expert Systems with Applications*, 38(12), 15194-15201.
- Lu, C. J., Lee, T. S. & Chiu, C. C. (2009). Financial time series forecasting using independent component analysis and support vector regression. *Decision Support Systems*, 47, 115–125.
- Ma, Y., Han, R. & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, 165(1), 1-15.
- Makridakis, S., Spiliotis, E. & Makridakis, M. (2020). M3-Competition: Results, conclusions, and way forward. *International Journal of Forecasting*, 36(1), 16-32.

- Mallikarjuna, M. & Rao, R. P. (2019). Evaluation of forecasting methods from selected stock market returns. *Financial Innovation*, 5(1), 40.
- Matías, J. M. & Reboredo, J. C. (2012). Forecasting performance of nonlinear models for Intraday Stock Returns. *Journal of Forecasting*, 31, 172–188.
- Miffre, J. (2007). Country-specific ETFs: an efficient approach to global asset allocation. *J. Asset Manag.* 8 (2), 112–122 .
- Mishra, V. K., Dasgupta, U., Patra, S., Pal, R. & Anand, K. (2022). A dynamic two-level artificial neural network for estimation of parameters in combined mode conduction-radiation heat transfer in porous medium: *An application to handle huge dataset with noise*, 51(2), 1306-1335.
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press.
- Namazi, M. & Kiamhar, M. (2007). Predicting Daily Stock Returns of Companies listed in Tehran Stock Exchange Using Artificial Neural Networks. *Financial Research Journal*, 9(24), 116-134. (in Persian)
- Nyukorong, R. (2020). Exchange-Traded Funds: What You Need to Know? *European Scientific Journal*, 1857-7881.
- Pant, M. & Kumar, S. (2022). Fuzzy time series forecasting based on hesitant fuzzy sets, particle swarm optimization and support vector machine-based hybrid method. *Granul. Comput.*, 7 (4), 861–879.
- Pasayat, A. K., Mitra, A. & Bhowmick, B. (2024). Determination of essential features for predicting start-up success: *an empirical approach using machine learning*. *Technology Analysis & Strategic Management*, 36(8), 1810-1828.
- Patel, M., Gupta, S. D. & Madhavan, V. (2023). Investment style consistency and performance of Indian fixed income mutual funds. *IIMB Management Review*, 35(3), 229-239.
- Phan, D. H. B., Sharma, S. S. & Narayan, P. K. (2015). Stock return forecasting: Some new evidence. *International Review of Financial Analysis*, 40, 38-51.
- Piovezan, R. P. B., de Andrade Junior, P. P. & Ávila, S. L. (2023). Machine Learning Method for Return Direction Forecast of Exchange Traded Funds (ETFs) Using Classification and Regression Models. *Computational Economics*, 1-26.
- Piovezan, R. P. & Junior, P. P. D. A. (2022). Machine learning method for return direction forecasting of Exchange Traded Funds using classification and regression models. *arXiv preprint arXiv*, 2205, 12746.
- Qureshi, F., Kutan, A. M., Ghafoor, A., Khan, H. H. & Qureshi, Z. (2019). Dynamics of mutual funds and stock markets in Asian developing economies. *Journal of Asian Economics*, 65, 2-16.
- Rajabi, R., Asgari, M., Dehghan, A. (2018). Prediction of stock returns of companies listed in Tehran Stock Exchange using data mining techniques (neural network (MLP) and general additive model (GAM). *New research approaches in management sciences*, 2 (10), 1-5. (in Persian)

- Rasel, R. I., Sultana, N. & Meesad, P. (2015). An efficient modelling approach for forecasting financial time series data using support vector regression and windowing operators. *International Journal of Computational Intelligence Studies*, 4(2), 134–150.
- Sahu, S., Yadav, M. K., Gupta, A. K., Uddameri, V., Toppo, A. N., Maheedhar, B. & Ghosal, P. S. (2022). Modeling defluoridation of real-life groundwater by a green adsorbent aluminum/olivine composite: Isotherm, kinetics, thermodynamics and novel framework based on artificial neural network and support vector machine. *Journal of Environmental Management*, 302, 2-14.
- Sharif far, A., Khaliliaraghi, M., Raeesi Vanani, I. & Fallahshams, M. (2022). Application of Deep Learning Architectures in Stock Price Forecasting: A Convolutional Neural Network Approach. *Journal of Asset Management and Financing*, 10(3), 1-20. (in Persian)
- Sharpe, W. F. (1994). The Sharpe ratio. *Journal of portfolio management*, 21(1), 49-58.
- Shu, T., Sulaeman, J. & Yeung, P. E. (2012). Local religious beliefs and mutual fund risk-taking behaviors. *Management Science*, 58(10), 1779–1796.
- Simutin, M. (2010). Excess cash and stock returns. *Financial Management*, 39(3), 1197-1222.
- Singhanian, M. & Saini, N. (2023). Institutional framework of ESG disclosures: comparative analysis of developed and developing countries. *Journal of Sustainable Finance & Investment*, 13(1), 516-559.
- Sirri, E. R. & Tufano, P. (1998). Costly search and mutual fund flows. *The journal of finance*, 53(5), 1589-1622.
- Tang, J., Henderson, A., Gardner, P., 2021. Exploring AdaBoost and random forests machine learning approaches for infrared pathology on unbalanced data sets. *Analyst*, 146 (19), 5880–5891.
- Tavakoli, S. & Ashtab, A. (2023). Comparison of the Effectiveness of Machine Learning Models and Statistical Models in Predicting Financial Risk. *Financial Management Strategy*, 11(1), 53-76. (in Persian)
- Torabi, T., Tarighi, S. & Tataei, P. (2016). A Review of Mutual Investment Funds Performance with a View of Market Timing. *International Journal of Finance & Managerial Accounting*, 1(3), 47-53.
- Treynor, J. L. (1965). How to rate management of investment funds. *Harvard business review*, 43(1), 63-75.
- Yu, J. R., Chiou, W. J. P., Lee, W. Y. & Lin, S. J. (2020). Portfolio models with return forecasting and transaction costs. *International Review of Economics & Finance*, 66, 118–130.
- Zhang, X., Zheng, Y., Lien, D. & Yu, X. (2024). Can mutual fund investors benefit from volatility managing? Evidence from China. *Pacific-Basin Finance Journal*, 83 (102228), 2-19
- Zhong, X., Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, 5(1), 2-20.