



Modeling and Predicting Initial Public Offering Returns Using Gradient Boosting Machine Learning Algorithms

Fatemeh Malmir

Ph.D. Candidate, Department of Accounting, Bo.C., Islamic Azad University, Borujerd, Iran.
E-mail: fa.malmir@iau.ac.ir

Farshid Kheirollahi *

*Corresponding Author, Assistant Prof., Department of Accounting, Faculty Economic and Accounting, Razi University, Kermanshah, Iran. E-mail: f.kheirollahi@razi.ac.ir

Hossein Yarahmadi

Assistant Prof., Department of Computer Engineering, Bo.C., Islamic Azad University, Borujerd, Iran, Iran. E-mail: hs.yarahmadi@iau.ac.ir

Farid Sefaty

Assistant Prof., Department of Accounting, Bo.C., Islamic Azad University, Borujerd, Iran.
E-mail: ayandeh1351@iau.ac.ir

Abstract

Objective

This research aims to develop a novel model based on the Gradient Boosting algorithm and Transformer architecture for accurately predicting corporate valuation ratios at the time of an Initial Public Offering (IPO) in the Iranian market. Contrary to traditional approaches focusing on first-day returns, this study evaluates the relative pricing of companies through three key ratios: Price-to-Book Value (P/B), Enterprise Value-to-Total Assets (EV/TA), and Enterprise Value-to-Sales (EV/S). Given the complexities of the Iranian market, including severe economic volatility, chronic inflation, economic sanctions, and regulatory restrictions, this research provides an efficient tool for investors, underwriters, and regulatory bodies to make more informed decisions.

Citation: Malmir, Fatemeh; Kheirollahi, Farshid; Yarahmadi, Hossein & Sefaty, Farid (2026). Modeling and Predicting Initial Public Offering Returns Using Gradient Boosting Machine Learning Algorithms. *Financial Research Journal*, 28(3), 885 – 932. <https://doi.org/10.22059/frj.2025.400625.1007779> (in Persian)



Methods

This quantitative applied study analyzes data from 163 companies, including 42 firms listed on the Tehran Stock Exchange and 121 firms traded on the over-the-counter market (Farabourse), covering the period from 2013 to 2023 (1392–1402 in the Iranian calendar). This period encompasses diverse economic conditions, including severe sanctions, currency fluctuations, recession, and economic booms. Independent variables included firm-specific financial features (size, debt ratio, profitability, return on assets, profit margin, cash flow ratio, financial leverage, and weighted average cost of capital) and macroeconomic variables (inflation rate, main stock market index, sanctions index, exchange rate, and interest rate). The proposed architecture is a hybrid of Gradient Boosting Decision Trees, Long Short-Term Memory (LSTM) networks, and self-attention mechanisms, optimized through an Automated Machine Learning (AutoML) architecture search. The optimal model configuration consisted of a learning rate of 0.001, 150 decision trees, four time steps, and three self-attention layers. The proposed model was compared with traditional methods (i.e., linear regression) and advanced approaches, including standard gradient boosting algorithms, random forests, and recurrent neural networks. Model performance was evaluated using ten-fold cross-validation and bootstrapping.

Results

The results demonstrated the decisive superiority of the proposed model in predicting all three valuation ratios. For the Price-to-Book Value ratio, the developed model achieved an R^2 of 0.853 and a Root Mean Square Error (RMSE) of 0.497, representing a 60% improvement in prediction accuracy compared to Linear Regression (R^2 of 0.534). In predicting the Enterprise Value-to-Total Assets (EV/TA) ratio, the model achieved an R^2 of 0.865 and reduced the Mean Squared Error (MSE) by 69%, from 0.152 to 0.047. For the Enterprise Value-to-Sales ratio, an R^2 of 0.846 was achieved, showing a 67% improvement in accuracy over traditional methods. Other advanced models also performed acceptably but did not reach the level of the proposed model. Cross-validation tests confirmed the model's high stability with a very low standard deviation (around 0.01), indicating its generalizability and reliability under various conditions. Variable importance analysis revealed that the inflation rate acts as the second most important factor across all models, with an average importance of 0.19, indicating the profound impact of macroeconomic conditions on corporate valuation in the Iranian market. Return on Assets (ROA) was identified as the most influential financial performance indicator for the P/B ratio (0.210), Profit Margin for the EV/S ratio (0.225), and Cash Flow-to-Assets Ratio for the EV/TA ratio (0.2).

Conclusion

The findings emphasize the importance of employing novel machine learning techniques in predicting IPO valuation ratios. The developed model, by reducing prediction error by 60% to 69%, provides an advanced tool for underwriters, investors, and fund managers to mitigate the risk of undervaluation or overvaluation. The identification of the pivotal role of the inflation rate highlights the high sensitivity of valuations to macroeconomic conditions in the Iranian market. This research contributes to three key areas: introducing a novel hybrid architecture, providing a comprehensive validation framework, and identifying the differential importance of variables for various valuation ratios under unstable economic conditions.

Keywords: Prediction, Initial Public Offering (IPO), Gradient boosting algorithm, Machine learning, Iranian capital market.

مدل سازی و پیش بینی بازده عرضه اولیه سهام با استفاده از الگوریتم های یادگیری

ماشین تقویت گرادیان

فاطمه مالمیر

دانشجوی دکتری، گروه حسابداری، واحد بروجرد، دانشگاه آزاد اسلامی، بروجرد، ایران. رایانامه: fa.malmir@iau.ac.ir

فرشید خیراللهی*

* نویسنده مسئول، استادیار، گروه حسابداری، دانشکده اقتصاد و حسابداری، دانشگاه رازی، کرمانشاه، ایران. رایانامه: f.kheirollahi@razi.ac.ir

حسین یاراحمدی

استادیار، گروه مهندسی کامپیوتر، واحد بروجرد، دانشگاه آزاد اسلامی، بروجرد، ایران. رایانامه: hs.yarahmadi@iau.ac.ir

فرید صفتی

استادیار، گروه حسابداری، واحد بروجرد، دانشگاه آزاد اسلامی، بروجرد، ایران. رایانامه: ayandeh1351@iau.ac.ir

چکیده

هدف: این پژوهش با هدف توسعه مدلی نوین مبتنی بر الگوریتم تقویت گرادیان و معماری ترانسفورمر برای پیش بینی دقیق نسبت های ارزش گذاری شرکت ها در زمان عرضه اولیه سهام در بازار ایران انجام شده است. برخلاف رویکردهای سنتی که بر بازده روز اول تمرکز دارند، این پژوهش قیمت گذاری نسبی شرکت ها را از طریق سه نسبت کلیدی (ارزش بازار به ارزش دفتری، ارزش شرکت به کل دارایی ها و ارزش شرکت به فروش) ارزیابی می کند. با توجه به پیچیدگی های بازار ایران، شامل نوسان های شدید اقتصادی، تورم مزمن، تحریم های اقتصادی و محدودیت های نظارتی، این پژوهش برای سرمایه گذاران، پذیره نویسان و نهادهای نظارتی، ابزاری کارآمد به منظور تصمیم گیری آگاهانه تر ارائه می دهد.

روش: این مطالعه با رویکرد کمی - کاربردی و با استفاده از داده های ۱۶۳ شرکت (۴۲ بورسی و ۱۲۱ فرابورسی) در بازه ۱۳۹۲ تا ۱۴۰۲ انجام شد. این دوره شامل شرایط اقتصادی متنوع از جمله تحریم های شدید، نوسان های ارزی، رکود و رونق اقتصادی است. متغیرهای مستقل شامل ویژگی های مالی شرکت ها (اندازه، نسبت بدهی، سودآوری، بازده دارایی ها، حاشیه سود، نسبت جریان نقدی، اهرم مالی و میانگین موزون هزینه سرمایه) و متغیرهای کلان اقتصادی (نرخ تورم، شاخص کل بورس، شاخص تحریم، نرخ ارز و نرخ بهره) بودند. معماری پیشنهادی، ترکیبی از الگوریتم های درختی تقویت گرادیان، شبکه های حافظه طولانی - کوتاه مدت و سازوکارهای خودتوجهی است که از طریق جست و جوی خودکار معماری بهینه سازی شد. پارامترهای بهینه عبارتند از: میزان یادگیری ۰/۰۰۱ و صدوپنجاه درخت

استناد: مالمیر، فاطمه؛ خیراللهی، فرشید؛ یاراحمدی، حسین و صفتی، فرید (۱۴۰۵). مدل سازی و پیش بینی بازده عرضه اولیه سهام با استفاده از الگوریتم های یادگیری ماشین تقویت گرادیان. *تحقیقات مالی*، ۲۸(۳)، ۸۸۵-۹۳۲.

تصمیم، چهار گام زمانی و سه لایه خودتوجهی. مدل با روش های سنتی (رگرسیون خطی) و پیشرفته (الگوریتم های تقویت گرادیان استاندارد، جنگل تصادفی و شبکه های عصبی بازگشتی) مقایسه و از طریق روش اعتبارسنجی متقابل ده تایی و بوت استرپ، اعتبارسنجی شد.

یافته ها: نتایج پژوهش برتری قاطع مدل پیشنهادی را در پیش بینی هر سه نسبت ارزش گذاری نشان داد. برای نسبت ارزش بازار به ارزش دفتری، مدل توسعه یافته با ضریب تعیین $0/853$ و ریشه میانگین مربعات خطای $0/497$ ، نسبت به رگرسیون خطی (ضریب تعیین $0/534$)، به بهبود 60 درصدی در دقت پیش بینی دست یافت. در پیش بینی نسبت ارزش شرکت به کل دارایی ها، ضریب تعیین $0/865$ و کاهش 69 درصدی میانگین مربعات خطا (از $0/152$ به $0/047$) به دست آمد. برای نسبت ارزش شرکت به فروش نیز با ضریب تعیین $0/846$ ، بهبود 67 درصدی در دقت نسبت به روش های سنتی مشاهده شد. سایر مدل های پیشرفته نیز عملکرد درخور توجهی داشتند؛ اما به سطح مدل پیشنهادی نرسیدند. آزمون های اعتبارسنجی متقابل، پایداری بسیار خوب مدل را با انحراف معیار بسیار پایین (در حدود $0/01$) تأیید کرد که نشان دهنده قابلیت تعمیم پذیری و اعتماد پذیری مدل در شرایط مختلف است. تحلیل اهمیت متغیرها نشان داد که میزان تورم با میانگین اهمیت $0/19$ ، به عنوان دومین عامل مهم در تمامی مدل ها عمل می کند که بیانگر تأثیر عمیق شرایط اقتصادی کلان بر ارزش گذاری شرکت ها در بازار ایران است. بازده دارایی ها با اهمیت $0/21$ برای نسبت ارزش بازار به ارزش دفتری، حاشیه سود با اهمیت $0/225$ برای نسبت ارزش شرکت به فروش و نسبت جریان نقدی به دارایی ها با اهمیت $0/2$ برای نسبت ارزش شرکت به دارایی ها، به عنوان مهم ترین شاخص های عملکرد مالی شناسایی شدند.

نتیجه گیری: یافته ها بر اهمیت به کارگیری تکنیک های نوین یادگیری ماشین در پیش بینی نسبت های ارزش گذاری عرضه های اولیه تأکید دارد. مدل توسعه یافته با کاهش 60 تا 69 درصدی خطای پیش بینی، ابزاری پیشرفته برای پذیره نویسان، سرمایه گذاران و مدیران سرمایه فراهم می آورد تا ریسک کم ارزش گذاری یا بیش ارزش گذاری را کاهش دهند. شناسایی نقش محوری نرخ تورم نشان دهنده حساسیت بسیار زیاد ارزش گذاری ها به شرایط کلان اقتصادی در بازار ایران است. این پژوهش در سه حوزه کلیدی مشارکت دارد: معرفی معماری نوین ترکیبی، ارائه چارچوب جامع اعتبارسنجی و شناسایی تفاوت های اهمیت متغیرها برای نسبت های مختلف ارزش گذاری در شرایط اقتصادی ناپایدار.

کلیدواژه ها: پیش بینی، عرضه اولیه سهام، الگوریتم تقویت گرادیان، یادگیری ماشین، بازار سرمایه ایران.

مقدمه

عرضه اولیه سهام^۱ به عنوان یکی از ابزارهای بسیار مهم تأمین مالی در بازارهای سرمایه، فرایندی است که طی آن شرکت‌های خصوصی برای نخستین بار سهام خود را در بازار عمومی عرضه می‌کنند (آلدانا و تریگوس^۲، ۲۰۲۵). این فرایند استراتژیک، نقطه عطفی در چرخه حیات شرکت‌ها محسوب می‌شود و در شرایط عدم اطمینان اقتصادی و نوسان‌های بازار با چالش‌های متعددی از جمله ریسک نقدینگی، عدم تقارن اطلاعاتی و احتمال شکست در جذب سرمایه مواجه است (عباسی و مارزولو، ۱۳۹۰).

مسئله اصلی این پژوهش ناکارآمدی روش‌های سنتی قیمت‌گذاری عرضه‌های اولیه سهام در بازار سرمایه ایران است که به زیان‌های درخور توجه برای سرمایه‌گذاران و عدم تخصیص بهینه منابع منجر می‌شود (شجاعی، عبدالباقی عطابادی و شیروانی، ۱۳۹۹). قیمت‌گذاری صحیح عرضه‌های اولیه سهام، به‌ویژه در شرایط عدم قطعیت اقتصادی و ریسک‌های سیستماتیک بازار، یکی از مسائل پُرچالش در بازارهای سرمایه محسوب می‌شود. به‌طور مشخص، آمارها نشان می‌دهد که بیش از ۶۰ درصد از عرضه‌های اولیه در بازار ایران، طی سال‌های اخیر با قیمت‌گذاری نامناسب مواجه بوده‌اند که به بازدهی منفی برای سرمایه‌گذاران اولیه یا زیان شرکت‌های عرضه‌کننده منجر شده است (نیک‌پی پسیان، رضازاده، احمدی نژاد و احمدوند، ۱۴۰۲؛ حیدری هراتمه و ابراهیمی، ۱۴۰۲)؛ به‌گونه‌ای که شواهد تجربی گسترده‌ای در بازارهای مختلف جهان نشان می‌دهند که پدیده قیمت‌گذاری نامناسب در عرضه‌های اولیه سهام، تحت تأثیر عوامل ریسک متعدد شامل نوسان‌های اقتصاد کلان، عدم اطمینان سیاسی و شوک‌های بازار امری فراگیر قرار می‌گیرد (چن، گویال، ویراقاوان و زولوتوی^۳، ۲۰۲۰؛ جمعانی و علی دروس^۴، ۲۰۱۹). در بازارهای توسعه‌یافته، بررسی‌ها حاکی از آن است که بازده روز اول معاملاتی عرضه‌های اولیه، به‌طور میانگین بین ۱۰ تا ۲۰ درصد با انحراف معیار شایان توجه است که نشان‌دهنده عدم قطعیت در ارزش‌گذاری و وجود ریسک‌های پیش‌بینی‌نشده است (فولبرون، نوگباور و نیکلیش^۵، ۲۰۱۴). در بازارهای نوظهور، این پدیده همراه با ریسک‌های ساختاری بیشتر، نظیر بی‌ثباتی نرخ ارز، تورم چشمگیر و نااطمینانی‌های نهادی با شدت بیشتری مشاهده می‌شود (آقایی، ۱۴۰۴؛ انگلن و ون اسن^۶، ۲۰۱۰؛ ایبوتسون، سیندلار و ریتز^۷، ۱۹۹۴).

مشکل اساسی در بازار سرمایه ایران این است که علاوه بر چالش‌های معمول بازارهای نوظهور، تحریم‌های بین‌المللی و انزوای اقتصادی کشور، لایه‌های پیچیده‌ای از عدم قطعیت و ریسک را به قیمت‌گذاری عرضه‌های اولیه اضافه کرده است. تحریم‌های اقتصادی از طریق محدودیت دسترسی به بازارهای بین‌المللی سرمایه، عدم امکان استفاده از سیستم‌های مالی جهانی، محدودیت در واردات تکنولوژی و تجهیزات و کاهش شدید صادرات نفت، ساختار ریسک

1. IPO
2. Aldana & Trigos
3. Chen, Goyal, Veeraraghavan & Zolotoy
4. Jamaani & Alidarous
5. Füllbrunn, Neugebauer & Nicklisch
6. Engelen & van Essen
7. Ibbotson, Sindelar & Ritter

بازار سرمایه ایران را به‌طور بنیادی تغییر داده است (قاسمی‌نژاد و جهان‌پرور^۱، ۲۰۲۱؛ حیدریان، پهلوانی و میرجلیلی^۲، ۲۰۲۵؛ زارعی، فلاحتی و ملک‌سعادت^۳، ۲۰۲۴). در بازار سرمایه ایران که تحت تأثیر شرایط خاص اقتصادی شامل تحریم‌های بین‌المللی، نوسان‌های شدید نرخ ارز، تورم مزمن و عدم ثبات سیاست‌های اقتصادی قرار دارد، عرضه‌های اولیه با ریسک‌های چندگانه و عدم قطعیت‌های فراوان مواجهند (باطنی، پورزمانی و رهنمای رودپشتی، ۱۳۹۲؛ نادری و اسپوکه، ۱۳۹۵؛ لشگرآرا، خدادادی، مطاهری و آیتی‌مهر، ۱۴۰۲؛ رضاییان، طالقانی و شرح‌شریفی، ۱۴۰۳؛ غفاری، عرب‌زاده، صفری‌گرایلی، جباری و رضایی‌پیتهنوی^۴، ۲۰۲۳). این تحریم‌ها باعث ایجاد پدیده‌های خاصی در بازار سرمایه ایران شده است که در سایر بازارها مشاهده نمی‌شود: نخست، «ریسک تحریمی» که احتمال تشدید یا کاهش تحریم‌ها را شامل می‌شود و تأثیر مستقیم بر ارزش‌گذاری شرکت‌ها دارد؛ دوم، «عدم قطعیت سیاسی - اقتصادی» ناشی‌گرفته از مذاکرات بین‌المللی که باعث نوسان‌های شدید در انتظارات بازار می‌شود؛ سوم، «انزوای تکنولوژیک» که دسترسی شرکت‌ها به فناوری‌های نوین را محدود کرده و قدرت رقابتی آن‌ها را کاهش می‌دهد.

نوآوری و راه‌حل پیشنهادی اصلی این پژوهش، در توسعه یک مدل بومی مبتنی بر الگوریتم تقویت گرادیان است که برخلاف مدل‌های موجود، قادر است متغیرهای خاص ناشی از تحریم‌ها و انزوای اقتصادی را در کنار سایر متغیرهای مالی و اقتصادی به‌طور هم‌زمان تحلیل کند. در این راستا، مدل‌سازی و پیش‌بینی بازده عرضه اولیه سهام با استفاده از الگوریتم‌های یادگیری ماشین تقویت گرادیان، رویکردی نوآورانه است که با در نظر گرفتن شرایط عدم اطمینان، ریسک‌های متعدد و نوسان‌های بازار، با بهره‌گیری از قدرت محاسباتی و تحلیلی الگوریتم‌های هوش مصنوعی، سعی در مدیریت ریسک و کاهش عدم قطعیت در قیمت‌گذاری دارد (وایدیناثان، کایال و مایتی^۵، ۲۰۲۵؛ کینتانا، سائز و ایسای^۶، ۲۰۱۷؛ افشاری‌راد، علوی و سینایی، ۱۳۹۷).

الگوریتم تقویت گرادیان، به‌عنوان یکی از تکنیک‌های بسیار قدرتمند یادگیری ماشین با ترکیب مدل‌های پیش‌بینی ضعیف و اصلاح تدریجی خطاها، این قابلیت را دارد که ضمن تحلیل سناریوهای مختلف ریسک، روابط پیچیده و غیرخطی میان متغیرهای مالی در شرایط عدم قطعیت را کشف کند (سوباسی^۷، ۲۰۲۰؛ خان، چاودری و چاندرا^۸، ۲۰۲۴). از جنبه مدیریت ریسک، قیمت‌گذاری عرضه‌های اولیه در شرایط عدم اطمینان اقتصادی ایران، به در نظر گرفتن طیف وسیعی از ریسک‌های سیستماتیک و غیرسیستماتیک شامل ریسک نقدینگی، ریسک اعتباری، ریسک عملیاتی و به‌ویژه ریسک‌های ناشی از تحریم‌ها و محدودیت‌های بین‌المللی نیازمند است (وقفی، صدیقی، پرن‌دین و حسینی‌عقدایی، ۱۴۰۴؛ دریایی، عزیزی و فتاحی^۹، ۲۰۲۲).

1. Ghasseminejad & Jahan-Parvar
2. Heydarian, Pahlavani & Mirjalili
3. Zareei, Falahi & Maleksadati
4. Ghafari, Arabzadeh, Safari Gerayli, Jabbari & Rezaei Pitenoei
5. Vaidynathan, Kayal & Maiti
6. Quintana, Sáez & Isasi
7. Subasi
8. Khan, Chaudhari & Chandra
9. Daryaei, Azizi & Fattahi

ریسک تحریمی، به عنوان عاملی منحصربه فرد در بازار سرمایه ایران، از طریق کانال های مختلفی شامل محدودیت دسترسی به منابع ارزی، افزایش هزینه های تأمین مواد اولیه، عدم امکان انتقال تکنولوژی و محدودیت در بازارهای صادراتی، بر ارزش گذاری شرکت ها تأثیر می گذارد (عابدیان و موسوی، ۱۴۰۳). بنابراین، ویژگی های خاص بازار سرمایه ایران از جمله عدم شفافیت اطلاعاتی، ضعف در حاکمیت شرکتی، نوسان های اقتصادی، تغییرات نرخ ارز و رفتار متمایز سرمایه گذاران که اغلب تحت تأثیر عوامل روانی و هیجانی قرار می گیرند، در کنار اثرهای روانی ناشی از تحریم ها و انزوای بین المللی که به بی اعتمادی و رفتارهای گله ای در بازار منجر می شود، ضرورت توسعه مدل های بومی با قابلیت تحلیل ریسک و عدم قطعیت برای پیش بینی دقیق بازده عرضه های اولیه را دوجندان می کند (خاتمی، زمردیان، فلاح شمس لیالستانی و مینوئی، ۱۴۰۱؛ حسینی، ابراهیمی سروعلیا، امیری و پیمانی فروشانی، ۱۴۰۲).

پیشرفت های اخیر در حوزه هوش مصنوعی و یادگیری ماشین، افق های جدیدی را برای مدیریت ریسک و تحلیل عدم قطعیت در بازارهای مالی گشوده است که به نیازهای موجود در قیمت گذاری عرضه های اولیه در شرایط پُرریسک و تحت تحریم، پاسخی مناسب ارائه می دهد (عباس حسن، پیری و چالاک، ۱۴۰۴؛ گان، ونگ و یانگ^۱، ۲۰۲۰). الگوریتم تقویت گرادیان، به طور خاص با توانایی مدیریت داده های پیچیده، تحلیل سناریوهای ریسک، شناسایی الگوهای غیرخطی و ترکیب متغیرهای متعدد در محیط های پُر نوسان و غیرقطعی و قابلیت یادگیری از داده های محدود و نویزی که مشخصه بازارهای تحت تحریم است، گزینه ای مناسب برای مدل سازی قیمت گذاری عرضه های اولیه محسوب می شود (عباسیان، شهرکی، فلاح پور و نمکی، ۱۴۰۲). مطالعات بین المللی نیز تأیید می کنند که استفاده از این الگوریتم ها می تواند با در نظر گرفتن عوامل ریسک و عدم قطعیت، دقت پیش بینی قیمت و بازده عرضه های اولیه را به میزان شایان توجهی افزایش دهد (بابا و سویل^۲، ۲۰۲۰؛ لین و مارکوس^۳، ۲۰۲۴). بنابراین، اهمیت و ضرورت توسعه مدل های پیش بینی دقیق برای عرضه های اولیه در بازار سرمایه ایران از ابعاد مختلف زیر قابل تبیین است:

نخست، با توجه به تحریم های بین المللی و محدودیت های دسترسی به بازارهای جهانی سرمایه، بازار داخلی در تأمین مالی بنگاه های اقتصادی نقش حیاتی ایفا می کند و بهبود کارایی عرضه های اولیه، می تواند به تقویت این نقش کمک شایانی کند (رضاییان و همکاران، ۱۴۰۳).

دوم، در شرایط انزوای اقتصادی و عدم امکان جذب سرمایه گذاری مستقیم خارجی، عرضه های اولیه به یکی از معدود گزینه های باقی مانده برای تأمین مالی شرکت ها تبدیل شده است که اهمیت قیمت گذاری صحیح آن ها را دوجندان می کند.

سوم، در شرایط تورم مزمن و کاهش ارزش پول ملی که تشدید آن ناشی از تحریم ها و کاهش درآمدهای ارزی است، عرضه های اولیه موفق می توانند به عنوان ابزاری برای حفظ ارزش دارایی های مردم و هدایت نقدینگی سرگردان به سمت بخش های مولد اقتصاد عمل کنند (خدیوی، بحری ثالث، جبارزاده کنگرلویی و زواری رضایی^۴، ۲۰۲۲).

1. Gun, Wang & Yang

2. Baba & Sevil

3. Lin & Marques

4. Khadivi, Bahri Sales, Jabbarzadeh Kangarluyi & Zavarirezaei

چهارم، با توجه به برنامه‌های خصوصی‌سازی و واگذاری شرکت‌های دولتی، توسعه مدل‌های دقیق قیمت‌گذاری که اثرهای تحریم‌ها را نیز لحاظ کند، می‌تواند از هدررفت منابع عمومی جلوگیری کرده و به توزیع عادلانه‌تر ثروت کمک کند (نصیری اقدم، جعفری شهرستانی، غلامی و پیروزراهی، ۱۴۰۳).

پنجم، در بستر اقتصاد دیجیتال و ظهور استارت‌آپ‌ها و شرکت‌های دانش‌بنیان که بسیاری از آن‌ها به دلیل تحریم‌ها با محدودیت‌های جدی در دسترسی به بازارهای جهانی و فناوری‌های روز مواجهند، مدل‌های پیش‌بینی مبتنی بر هوش مصنوعی، می‌توانند ریسک‌های خاص این نوع کسب‌وکارها را بهتر شناسایی و مدیریت کنند (حیدری و امیری، ۱۴۰۱). در نهایت، توسعه چنین مدل‌هایی می‌تواند با کاهش عدم قطعیت ناشی از تحریم‌ها و ارائه تصویری شفاف‌تر از ریسک‌های موجود، به ارتقای جایگاه بازار سرمایه ایران در منطقه، افزایش اعتماد سرمایه‌گذاران داخلی و در نتیجه بهبود شاخص‌های کلان اقتصادی کشور منجر شود.

بر این اساس، هدف اصلی این پژوهش، توسعه و ارزیابی مدلی مبتنی بر الگوریتم تقویت گرادیان برای مدل‌سازی و پیش‌بینی دقیق بازده عرضه اولیه سهام با در نظر گرفتن شرایط عدم قطعیت، ریسک‌های چندگانه و نوسان‌های ساختاری در بازار سرمایه ایران است. این مطالعه با بهره‌گیری از قابلیت‌های پیشرفته الگوریتم تقویت گرادیان در تحلیل داده‌های پیچیده و نامتوازن در شرایط عدم اطمینان و شناسایی الگوهای پنهان تحت تأثیر ریسک‌های سیستماتیک و غیرسیستماتیک، می‌کوشد تا ابزاری کارآمد برای کمک به تصمیم‌گیری آگاهانه و ریسک‌محور ذی‌نفعان بازار سرمایه، شامل شرکت‌های عرضه‌کننده، سرمایه‌گذاران و تنظیم‌کنندگان بازار ارائه کند. به عبارت دیگر، این پژوهش در پی پاسخ به این سؤال اصلی است که آیا استفاده از الگوریتم تقویت گرادیان، می‌تواند در شرایط عدم قطعیت اقتصادی و وجود ریسک‌های متعدد بازار سرمایه ایران، دقت پیش‌بینی بازده عرضه‌های اولیه سهام را در مقایسه با روش‌های سنتی که عمدتاً بر فرض‌های ساده‌انگارانه و شرایط ایدئال مبتنی هستند، به‌طور معناداری بهبود بخشد؟ همچنین این پژوهش به دنبال شناسایی مهم‌ترین عوامل ریسک و عدم قطعیت مؤثر بر عملکرد عرضه‌های اولیه در بازار ایران و ارائه چارچوبی جامع برای مدیریت این ریسک‌ها از طریق مدل‌سازی پیشرفته است.

ساختار پژوهش شامل مروری بر ادبیات استفاده از یادگیری ماشین، به‌ویژه الگوریتم تقویت گرادیان در پیش‌بینی بازده عرضه اولیه سهام، تشریح روش جمع‌آوری داده‌ها و مدل‌سازی، ارائه نتایج و مقایسه عملکرد الگوریتم با روش‌های سنتی و در پایان تحلیل یافته‌ها، بررسی مزیت‌ها و محدودیت‌ها و پیشنهادهایی برای پژوهش‌های آتی خواهد بود. منابع استفاده‌شده نیز در انتها ارائه شده است.

ادبیات نظری و پیشینه پژوهش

عرضه اولیه سهام^۱، به‌عنوان فرایندی که شرکت‌های خصوصی از طریق آن سهام خود را برای نخستین بار در بازار سرمایه عرضه می‌کنند، در تاریخ بازارهای مالی سابقه‌ای کهن دارد. نخستین شواهد مستند از عرضه اولیه سهام، به قرن

هفدهم میلادی و شرکت هلندی^۱ بازمی‌گردد (واسیچ^۲، ۲۰۲۰؛ درودوین^۳، ۲۰۲۳). از منظر تئوریک، عرضه اولیه سهام، نمادی از انتقال مالکیت از حوزه خصوصی به عمومی محسوب می‌شود که با چالش‌های اساسی نظیر عدم تقارن اطلاعاتی، مسئله نمایندگی و ارزش‌گذاری دشوار همراه است (کامیابی و بوربوری، ۱۳۹۵).

تئوری‌های کلاسیک مالی شامل سه رکن اصلی هستند:

اول، نظریه بازار کارآمد فاما^۴ (۱۹۷۰) که بیان می‌کند قیمت‌ها بلافاصله تمام اطلاعات موجود را منعکس می‌کنند؛

اما این نظریه در توضیح پدیده قیمت‌گذاری پایین عرضه اولیه با محدودیت مواجه است.

دوم، نظریه سیگنال‌دهی راس^۵ (۱۹۷۷) که نشان می‌دهد شرکت‌ها از طریق قیمت‌گذاری پایین، سیگنال کیفیت

بالای خود را به بازار ارسال می‌کنند، هرچند این نظریه نمی‌تواند تنوع بالای بازده‌های اولیه را توجیه کند.

سوم، پدیده قیمت‌گذاری پایین‌تر از حد انتظار^۶ که توسط ایبوتسون^۷ (۱۹۷۵) مستندسازی شد و نخستین تناقض

جدی با فرضیه‌های بازار کارآمد را آشکار ساخت، نشان‌دهنده نیاز به رویکردهای جدیدتر در مدل‌سازی است.

از طرفی دیگر، تحولات نظری مدرن در حوزه عرضه اولیه سهام بر پیچیدگی‌های اطلاعاتی و رفتاری متمرکز

شده‌اند که خلأهای نظری تئوری‌های کلاسیک را برطرف می‌سازند؛ به‌گونه‌ای که نظریه مزایده کتابچه‌سازی^۸ توسط

بنونیست و اسپیندت^۹ (۱۹۸۹) با وجود توضیح سازوکار قیمت‌گذاری پویا، در عمل نتوانسته است دقت پیش‌بینی مناسبی

ارائه دهد. مطالعات درین و ووماک^{۱۰}، (۲۰۰۳) نشان می‌دهد که حتی با در نظر گرفتن اطلاعات خصوصی سرمایه‌گذاران

نهادی، مدل‌های سنتی همچنان خطای بالایی در پیش‌بینی دارند. هم‌زمان، نظریه‌های رفتاری مالی از جمله تئوری

احساسات سرمایه‌گذار^{۱۱} بیکر و ورگلر^{۱۲} (۲۰۰۶) و نظریه گله‌وارگی (نظریه هردینگ^{۱۳})، تصمیم‌گیری روان‌شناختی در

بازار عرضه اولیه سهام را برجسته می‌سازد (لوپز کابارکوس، پرز پیکو، وازکز رودریگز و لوپز پرز،^{۱۴} ۲۰۱۹). با این حال،

این نظریه‌ها عمدتاً توصیفی بوده و فاقد قدرت پیش‌بینی کمی هستند. این شکاف نظری، ضرورت استفاده از روش‌های

محاسباتی پیشرفته را برای ترکیب عوامل بنیادی، رفتاری و بازاری در یک چارچوب یکپارچه نشان می‌دهد (نیک پی

پسیان و همکاران، ۱۴۰۲؛ لی، باخ و بایک^{۱۵}، ۲۰۱۱).

1. East India Company

2. Vasić

3. Drooduin

4. Fama

5. Ross

6. Under-pricing

7. Ibbotson

8. Book-building Theory

9. Benveniste & Spindt

10. Derrien & Womack

11. Investor Sentiment Theory

12. Baker & Wurgler

13. Herding Theory

14. López-Cabarcos, Pérez-Pico, Vázquez Rodríguez & López-Pérez

15. Lee, Bach & Baik

از طرفی دیگر، ظهور یادگیری ماشین و به‌ویژه الگوریتم‌های تقویت گرادیان^۱، پارادایم جدیدی در تحلیل و پیش‌بینی بازارهای مالی ایجاد کرده است.

الگوریتم‌های تقویت گرادیان نسبت به روش‌های سنتی، سه مزیت کلیدی دارند: اول، قابلیت مدل‌سازی روابط غیرخطی پیچیده بدون نیاز به فرضیات محدودکننده توزیع آماری؛ دوم، توانایی ترکیب تکراری مدل‌های ضعیف برای ایجاد یک مدل قوی که خطای پیش‌بینی را به حداقل می‌رساند؛ سوم، مقاومت در برابر داده‌های پرت و نویزی که در بازارهای مالی رایج است. تقویت گرادیان که بر پایه کارهای فریدمن^۲ (۲۰۰۱) در گرادیان تقویتی^۳ و توسعه‌های بعدی چن و گسترین^۴ (۲۰۱۶) و کی و همکاران^۵ (۲۰۱۷) در ماشین بسیار سریع تقویتی گرادیان^۶ استوار است، در مقایسه با شبکه‌های عصبی عمیق، از نظر قابلیت تفسیر برتری دارد و نسبت به روش‌های درختی سنتی، دقت بیشتری در پیش‌بینی ارائه می‌دهد (عباسیان و همکاران، ۱۴۰۲). این الگوریتم‌ها از طریق ترکیب تدریجی مدل‌های ضعیف و بهینه‌سازی تابع هدف با استفاده از گرادیان‌های خطا، قادر به کشف روابط پیچیده‌ای هستند که روش‌های سنتی اقتصادسنجی از شناسایی آن‌ها عاجزند (اشمیت^۷، ۲۰۲۲). در حوزه مالی، این قابلیت‌ها امکان در نظرگیری هم‌زمان صدها متغیر تأثیرگذار بر بازده عرضه اولیه سهام، از شاخص‌های کلان اقتصادی تا ویژگی‌های خرد شرکت و احساسات بازار را فراهم می‌آورد (دوان و همکاران^۸، ۲۰۱۶).

همگرایی نظریه‌های مالی مدرن با الگوریتم‌های تقویت گرادیان، چارچوب جامعی برای درک و پیش‌بینی بازده عرضه اولیه سهام ارائه می‌دهد که هم در تئوری‌های اقتصادی ریشه دارد و هم از قدرت محاسباتی مدرن بهره می‌برد (ژانگ، کای و ون^۹، ۲۰۲۴). این رویکرد تلفیقی، سه شکاف اصلی در ادبیات موجود را پُر می‌کند: اول، ناتوانی مدل‌های خطی در کشف روابط پیچیده؛ دوم، عدم توانایی نظریه‌های رفتاری در ارائه پیش‌بینی کمی؛ سوم، محدودیت روش‌های سنتی در پردازش حجم بالای داده‌ها (لیو، یان، گو و گو^{۱۰}، ۲۰۲۲). علاوه بر این، قابلیت تقویت گرادیان در مدیریت عدم قطعیت و نوفه بازار، آن را به ابزاری مناسب برای مواجهه با ماهیت احتمالاتی و پویای بازده عرضه اولیه سهام تبدیل می‌کند (عباسیان و همکاران، ۱۴۰۲). این همگرایی نه تنها دقت پیش‌بینی را افزایش می‌دهد، بلکه درک عمیق‌تری از سازوکارهای اساسی تأثیرگذار بر عملکرد عرضه اولیه سهام ارائه می‌دهد و زمینه را برای توسعه استراتژی‌های سرمایه‌گذاری پیشرفته و سیاست‌گذاری‌های نظارتی مؤثرتر فراهم می‌آورد (لی و لی^{۱۱}، ۲۰۲۵).

بنابراین، تحولات اخیر در ادبیات پژوهش نشان می‌دهد که ترکیب الگوریتم‌های تقویت گرادیان با تکنیک‌های

1. Gradient Boosting

2. Friedman

3. XGBoost

4. Chen

5. Ke et al.

6. LightGBM

7. Schmitt

8. Duan et al.

9. Zhang, Cai & Wen

10. Liu, Yan, Guo & Guo

11. Li and Li

مدرن پردازش زبان طبیعی^۱ و تحلیل احساسات، افق‌های جدیدی در پیش‌بینی بازده عرضه اولیه سهام گشوده است. پژوهش‌های پیشین نظیر نجفی، بهرامی و حسینی (۱۴۰۳) و هیبتی و مرادی (۱۳۸۹) با وجود نشان دادن اهمیت عوامل کیفی، فاقد چارچوب یکپارچه برای ترکیب این عوامل با متغیرهای کمی بوده‌اند. همچنین، این مطالعات عمدتاً از روش‌های آماری سنتی استفاده کرده‌اند که توانایی محدودی در مدل‌سازی تعاملات پیچیده دارند. این تحولات، همراه با رشد فزاینده داده‌های جایگزین^۲ و پردازش بی‌درنگ اطلاعات، زمینه‌ساز ایجاد نسل جدیدی از سیستم‌های پیش‌بینی هوشمند است که نه تنها دقت بسیار زیادی دارند، بلکه قابلیت دارند تا با شرایط متغیر بازار و ارائه توضیحات منطقی برای تصمیم‌های خود تطبیق یابند (آل احمدی^۳، ۲۰۲۵؛ لین و مارکوس، ۲۰۲۴).

در خصوص پیش‌بینی بازده عرضه اولیه سهام مطالعات تجربی متعددی وجود دارد که در ادامه مورد بررسی قرار گرفته است. روی، چوپرا، لی، اسپمپیناتو و محمدی ابواتلود^۴ (۲۰۲۰) در مطالعه‌ای با عنوان «جنگل تصادفی، ماشین‌های گرادیان بوستینگ و شبکه عصبی عمیق برای پیش‌بینی قیمت سهام: تحلیل مقایسه‌ای روی شرکت‌های کره جنوبی»، به مقایسه روش‌های مختلف یادگیری ماشین در پیش‌بینی قیمت سهام پرداختند. آن‌ها یک رویکرد مبتنی بر شبکه عصبی عمیق را برای پیش‌بینی افزایش ۲۵ درصدی قیمت سهام در سال آینده پیشنهاد دادند و این روش را با رویکردهای کم‌عمق مانند جنگل تصادفی و ماشین‌های گرادیان بوستینگ مقایسه کردند. با این حال، یک نقطه ضعف کلیدی این مطالعه، بی‌توجهی به ویژگی‌های خاص بازار IPO و تمرکز صرف بر بازار ثانویه بود. همچنین، استفاده از شبکه عصبی عمیق با وجود دقت بالا ($AUC = 0.806$)، مشکل جعبه سیاه بودن و عدم قابلیت تفسیر را به همراه داشت که برای تصمیم‌گیری در بازارهای مالی محدودیت ایجاد می‌کند.

در ادامه، سعیدی اقدم، صادقی، بحیرایی و حاجی اصغری (۱۴۰۱) در پژوهشی با عنوان «ارائه مدل پیش‌بینی قیمت سهام با استفاده از الگوریتم‌های یادگیری عمیق و کاربرد آن در قیمت‌گذاری سهام بانک‌های اسلامی»، به ارائه مدلی ترکیبی برای پیش‌بینی روند حرکتی قیمت سهام با استفاده از شبکه عصبی مصنوعی پرداختند. این مطالعه نشان داد که مدل یادگیری عمیق نسبت به روش‌های سنتی عملکرد بهتری دارد؛ اما سه ضعف عمده داشت: اول، محدودیت نمونه به سه ماهه که تعمیم‌پذیری را کاهش می‌دهد؛ دوم، عدم مقایسه با الگوریتم‌های تقویت گرادیان که عملکرد بهتری در داده‌های ساختاریافته دارند؛ سوم، بی‌توجهی به ویژگی‌های خاص IPO و تمرکز صرف بر بازار ثانویه.

گیرتسما و لو^۵ (۲۰۲۳) در مطالعه‌ای با عنوان «ارزش‌گذاری نسبی با یادگیری ماشین» به بررسی کاربرد روش‌های یادگیری ماشین در ارزش‌گذاری نسبی سهام پرداختند. در این پژوهش روش‌های نوین یادگیری ماشین را برای بهبود ارزش‌گذاری سهام مورد بررسی قرار گرفت. نتایج مطالعه نشان‌دهنده پتانسیل شایان توجه رویکردهای یادگیری ماشین در بهبود دقت پیش‌بینی ارزش سهام و کمک به تصمیم‌گیری‌های سرمایه‌گذاری است. این مطالعه نقطه عطفی در کاربرد

1. NLP

2. Alternative Data

3. Alahmadi

4. Roy, Chopra, Lee, Spampinato & Mohammadi-Ivatlood

5. GEERTSEMA & LU

یادگیری ماشین برای ارزش گذاری نسبی محسوب می شود؛ اما فاقد تمرکز خاص بر IPO است. همچنین، عدم استفاده از الگوریتم های تقویت گرادیان پیشرفته و اکتفا به روش های پایه ای یادگیری ماشین، فرصتی از دست رفته برای بهبود دقت پیش بینی است.

از سویی دیگر، ناکاگوا و یوشیدا^۱ (۲۰۲۲) در مقاله ای با عنوان «درخت گرادیان بوستینگ سری زمانی برای پیش بینی قیمت سهام»، یک روش گرادیان بوستینگ درختی مبتنی بر سری های زمانی برای مجموعه داده هایی با ویژگی های سری زمانی و مقطعی پیشنهاد دادند. مدل آن ها دارای یادگیرنده های ضعیف با ویژگی های سری زمانی و مقطعی در گره های داخلی است که نمونه ها را بر اساس شباهت بین جفت سری های زمانی یا ناخالصی بین ویژگی های مقطعی تقسیم می کند. آن ها با تحلیل تجربی روی شاخص های اصلی جهانی نشان دادند که روش پیشنهادی از نظر سودآوری و دقت نسبت به روش های قبلی برتری دارد. نوآوری کلیدی این مطالعه، ترکیب ویژگی های زمانی و مقطعی بود که برای تحلیل IPO بسیار مناسب است. با این حال، پیچیدگی محاسباتی بالا و نیاز به حجم زیاد داده برای آموزش مؤثر، کاربرد آن را در بازارهای نوظهور با داده محدود دشوار می سازد.

لی^۲ (۲۰۲۳) در مطالعه ای با عنوان «تخمین قیمت های بازار سهام با رگرسیون تقویت گرادیان مبتنی بر هیستوگرام: مطالعه موردی روی شرکت الفبت^۳» به تخمین قیمت های سهام با استفاده از رگرسیون تقویت گرادیان مبتنی بر هیستوگرام پرداخت. یافته ها نشان دهنده بهبود چشمگیری در دقت در مقایسه با مدل های سنتی تقویت گرادیان بود. قدرت ترکیبی^۴ و تکنیک های بهینه سازی مختلف از جمله بهینه سازی ازدحام ذرات، الگوریتم کپک مخاطی و بهینه سازی گرگ خاکستری، نه تنها دقت پیش بینی را افزایش داد، بلکه توانایی مدل را برای تطبیق با شرایط متغیر بازار تقویت کرد. این مطالعه نشان داد که الگوریتم های تقویت گرادیان مبتنی بر هیستوگرام (مانند LightGBM) سرعت محاسباتی را تا ۲۰ برابر افزایش می دهند، در حالی که دقت را حفظ می کنند. این مزیت برای تحلیل بی درنگ IPO حیاتی است؛ اما محدودیت اصلی، تمرکز بر یک شرکت منفرد (الفبت) است که تعمیم پذیری یافته ها را محدود می کند.

در ادامه هراتمه و ابراهیمی (۱۴۰۲) در پژوهشی با عنوان «بررسی تأثیر عرضه عمومی و اولیه سهام بر عملکرد مالی شرکت ها»، به بررسی تأثیر عرضه عمومی اولیه سهام بر عملکرد مالی شرکت های پذیرفته شده در بورس اوراق بهادار تهران پرداختند. در این مطالعه از طریق نمونه گیری غربالگری از بین ۴۵۸ شرکت در دوره زمانی ۱۳۹۸ تا ۱۴۰۲، تعداد ۱۳۲ شرکت به عنوان نمونه انتخاب و با رویکرد پنل دیتا برای ۶۶۰ مشاهده (سال - شرکت) الگوی رگرسیونی چندمتغیره برآورد شد. نتایج این پژوهش نشان داد که عرضه عمومی تأثیر منفی اما غیرمعناداری بر نسبت سود خالص به کل دارایی ها دارد که تأثیر منفی عرضه عمومی بر عملکرد مالی شرکت ها را نشان می دهد و این ضریب از نظر آماری معنادار بوده است. اگرچه این مطالعه بینش های ارزشمندی درباره تأثیر منفی IPO بر عملکرد کوتاه مدت ارائه داد؛ اما دو

1. Nakagawa & Yoshida

2. Li

3. Alphabet

4. HGBost

محدودیت عمده داشت: اول، استفاده از روش‌های آماری سنتی که قادر به کشف روابط غیرخطی نیستند؛ دوم، عدم ارائه مدل پیش‌بینی که کاربرد عملی یافته‌ها را محدود می‌کند.

از سویی دیگر، گوپتا و کومار^۱ (۲۰۲۳) در پژوهشی با عنوان «مدل ماشین تقویت گرادیان سبک مبتنی بر بهینه‌سازی هیبریدی هریس هاوک برای تجارت بی‌درنگ» یک مدل ماشین تقویت گرادیان سبک^۲ بهینه‌شده، با استفاده از الگوریتم بهینه‌سازی هیبریدی هریس هاوک^۳ برای پیش‌بینی تجارت ارائه دادند. آن‌ها مشکل بیش‌برازش در بهینه‌سازی متعارف هریس هاوک را با استفاده از روش‌های دسته‌بندی و ویژگی انحصاری^۴ و نمونه‌برداری یک‌طرفه مبتنی بر گرادیان^۵ برطرف کردند. نتایج نشان داد که پارامترهای ورودی در پیش‌بینی رشد اقتصادی در رابطه با سیستم تجارت بین‌بازاری^۶ و خدمات با دقت بالاتری کارآمد بودند. نقطه قوت این مطالعه، حل مشکل بیش‌برازش و بهینه‌سازی فرامکاشف‌های پارامترها بود. با این حال، پیچیدگی الگوریتم ترکیبی و زمان محاسباتی بالا، کاربرد عملی آن را محدود می‌کند. همچنین، آزمون نکردن آن روی داده‌های IPO، شکاف مهمی در این پژوهش است.

عباسیان و همکاران (۱۴۰۲) در پژوهشی با عنوان «رویکردی نوین در پیش‌بینی درماندگی مالی با به‌کارگیری اطلاعات مبتنی بر شبکه مالی و روش ترکیبی درخت تصمیم تقویت گرادیان»، به بررسی عملکرد الگوی درخت تصمیم تقویت گرادیان با افزودن متغیرهای مربوط به شبکه مالی پرداختند. آن‌ها الگوی پیشنهادی خود را روی داده‌های ۱۲۳ شرکت تولیدی پذیرفته شده در بورس و فرابورس ایران در بازه زمانی ۲۰۱۵ تا ۲۰۲۱ اجرا کردند. نتایج نشان داد که الگوی درخت تصمیم تقویت گرادیان با اضافه شدن متغیرهای مربوط به شبکه مالی، هم از نظر دقت و هم از نظر خطای نوع یک، در مقایسه با دو الگوی k نزدیک‌ترین همسایه و رگرسیون لجستیک، عملکرد بهتری از خود نشان داد. همچنین محققان دریافتند که شرکت‌های با مرکزیت بینابینی و مرکزیت درجه زیاد، کمتر مستعد قرارگرفتن در شرایط درماندگی مالی هستند. این مطالعه نشان داد که افزودن متغیرهای شبکه‌ای، دقت پیش‌بینی را تا ۱۵ درصد بهبود می‌بخشد. این یافته برای تحلیل IPO که در آن روابط بین شرکت‌ها و بانک‌های سرمایه‌گذاری حیاتی است، بسیار مهم است. نقطه ضعف اصلی، عدم بررسی عملکرد در بازارهای صعودی و نزولی مختلف بود.

نیک پی و همکاران (۲۰۲۳) در پژوهشی با عنوان «بررسی رابطه علیت بین عرضه اولیه سهام و عوامل کلان اقتصادی»، به بررسی رابطه علیت گرنجری بین تعداد عرضه‌های اولیه سهام با فاکتورهای کلان اقتصادی از جمله تولیدات صنعتی، نرخ بهره به بدهی دولت، بازار سهام و نوسان‌های بازار سهام ایران پرداختند. به‌منظور دستیابی به هدف فوق، از الگوی خودرگرسیون برداری^۷، طی دوره زمانی ۱۳۷۰ تا ۱۳۹۸ استفاده کردند. یافته‌های این پژوهش نشان داد که تعداد عرضه‌های اولیه، علیت گرنجری رشد تولیدات صنعتی و نوسان‌های شاخص کل است و مشخص شد که تعداد

1. Gupta & Kumar
2. Light GBM
3. H3O
4. EFB
5. GOSS
6. ITS
7. VAR

عرضه اولیه، علت رشد شاخص کل و نوسان‌های بازار سهام و نرخ بهره به بدهی دولت بوده است. براساس نتایج حاصل شده، محققان ادعا کردند که منابع مالی به‌دست‌آمده از طریق تعداد عرضه‌های اولیه شرکت‌ها، همه نباید صرف هزینه دولت شود و بهتر است منابع مالی به‌دست‌آمده، صرف توسعه و پیشرفت این شرکت‌ها و بازار سهام شود. این مطالعه شکاف مهمی در ادبیات داخلی را با بررسی عوامل کلان پر کرد؛ اما محدودیت‌های جدی داشت: اول، استفاده از مدل VAR خطی که روابط غیرخطی را نادیده می‌گیرد؛ دوم، تمرکز بر تعداد IPO به جای بازده آن‌ها؛ سوم، عدم ارائه مدل پیش‌بینی کاربردی.

هوما و نیشات^۱ (۲۰۲۴) در پژوهشی به بررسی کاربرد ماشین تقویت گرادیان سبک^۲ در پیش‌بینی قیمت سهام پرداختند. این مقاله بر نقش حیاتی مهندسی ویژگی تأکید کرده است. محققان با ادغام ویژگی‌های زمانی، فنی و مبتنی بر احساسات، نشان دادند که رویکرد ماشین تقویت گرادیان سبک در مقایسه با روش‌های سنتی، در دقت پیش‌بینی بهبود شایان توجهی دارد؛ زیرا در مدیریت کارآمد داده‌های بزرگ‌مقیاس، مدل‌سازی تعاملات پیچیده و ارائه زمان‌های آموزشی سریع مورد توجه قرار گرفته است. این مطالعه با تأکید بر مهندسی ویژگی و ترکیب ویژگی‌های زمانی، فنی و احساسی، رویکرد جامعی ارائه داد. نتایج نشان داد که LightGBM تا ۳۰ درصد سریع‌تر از XGBoost با حفظ دقت مشابه عمل می‌کند. این برتری برای تحلیل بی‌درنگ IPO که زمان حیاتی است، بسیار مهم است؛ اما عدم آزمون روی داده‌های IPO، شکاف اصلی این مطالعه است.

قلابی، سوئیسی، دو و علی^۳ (۲۰۲۵) در مطالعه‌ای با عنوان «پیش‌بینی بازارهای سهام^۴ و قیمت‌های انرژی پاک: بینش‌هایی از یادگیری ماشین پیشرفته»، به پیش‌بینی قیمت‌های سهام انرژی پاک از طریق تحلیل بازارهای سهام در ده کشور با استفاده از تکنیک‌های یادگیری ماشین و تقویت گرادیان بوستینگ^۵ پرداختند. این تحلیل، مقادیر توضیح افزودنی شیلی را برای بهبود قابلیت تفسیر ادغام کرد. نتایج نشان داد که تقویت گرادیان بوستینگ نسبت به سایر مدل‌ها عملکرد بهتری دارد و هم‌بستگی قابل توجهی بین قیمت‌های سهام انرژی پاک و متغیرهای بازار ESG وجود دارد. این یافته‌ها پتانسیل تکنیک‌های یادگیری ماشین را در پیش‌بینی روندهای سهام انرژی پاک برجسته کرده و بینش‌های ارزشمندی را برای سرمایه‌گذاران، سیاست‌گذاران و سرمایه‌گذاران خطرپذیر فراهم آورده است. یافته‌های این پژوهش نشان می‌دهد که رویکردهای تقویت گرادیان بوستینگ، به‌طور مؤثری برای مدل‌سازی و پیش‌بینی ارتباط بین شاخص‌های ESG و بازارهای انرژی پاک استفاده شوند. نقطه قوت این مطالعه، ادغام شاخص‌های ESG و استفاده از SHAP برای تفسیرپذیری است. نتایج نشان داد که تقویت گرادیان در مقایسه با رگرسیون خطی، ۱۲ درصد دقت بیشتری دارد؛ اما تمرکز بر بخش انرژی و عدم بررسی IPO، کاربرد آن را برای پژوهش حاضر محدود می‌کند.

1. Huma & Nishat

2. LightGBM

3. Ghallabi, Souissi, Du & Ali

4. ESG

5. NGBoost

ملا میر، خیراللهی، یاراحمدی و صفتی^۱ (۲۰۲۵). به توسعه مدلی مبتنی بر الگوریتم گرادیان بوستینگ برای پیش‌بینی قیمت‌گذاری نسبی عرضه‌های اولیه عمومی در بازار سهام ایران پرداختند. این مطالعه نزدیک‌ترین پژوهش به موضوع حاضر است و نشان داده است که الگوریتم‌های تقویت گرادیان در پیش‌بینی IPO ایران عملکرد مناسبی دارند. با این حال، سه محدودیت کلیدی در این پژوهش وجود دارد: اول، عدم استفاده از معماری‌های پیشرفته ترکیبی؛ دوم، تمرکز بر یک متغیر وابسته؛ سوم، عدم ادغام تحلیل احساسات و داده‌های جایگزین.

منصوری، مؤمنی و کاظمی میان گسکری^۲ (۲۰۲۶) در پژوهش خود به این موضوع پرداختند که پیش‌بینی دقیق فروش برای مدیریت موجودی و برنامه‌ریزی زنجیره تأمین در محیط‌های خرده‌فروشی با تنوع بالای محصول، چرخه عمر کوتاه و تقاضای ناپایدار بسیار مهم است. خطاها باعث موجودی اضافی، اتمام موجودی، فروش از دست رفته، تبلیغات غیربهره‌مند، هزینه‌های بالاتر، کاهش رضایت مشتری و آسیب به برند می‌شوند. پیش‌بینی‌های قابل اعتماد، باعث افزایش موجودی، قیمت‌گذاری، طراحی تبلیغات، تخصیص موجودی و سودآوری می‌شوند. از آنجایی که خرده‌فروشان از استراتژی‌های مبتنی بر داده استقبال می‌کنند، مدل‌ها باید تعاملات بین تقاضا، قیمت‌گذاری و موجودی را در نظر بگیرند. این مطالعه یک چارچوب شبکه عصبی عمیق را معرفی می‌کند که به‌طور مشترک پیش‌بینی تقاضا و بهینه‌سازی تخفیف را انجام می‌دهد.

شکاف پژوهشی و نوآوری پژوهش

با مرور جامع پیشینه پژوهش، چهار شکاف اساسی و بنیادین در ادبیات موجود شناسایی می‌شود که ضرورت انجام این پژوهش را توجیه می‌کند. نخستین شکاف، فقدان مدل‌های یکپارچه و چندبعدی برای قیمت‌گذاری نسبی عرضه اولیه سهام است. مطالعات بین‌المللی همچون روی و همکاران (۲۰۲۰)، ناکاگاوا و یوشیدا (۲۰۲۲) و لی (۲۰۲۳)، عمدتاً بر پیش‌بینی قیمت سهام در بازار ثانویه متمرکز بوده‌اند و ویژگی‌های منحصربه‌فرد بازار عرضه اولیه سهام، از جمله عدم تقارن اطلاعاتی شدید، محدودیت داده‌های تاریخی و رفتار متمایز سرمایه‌گذاران را نادیده گرفته‌اند. حتی مطالعه ملا میر و همکاران (۲۰۲۵) که به صراحت بر عرضه اولیه سهام در ایران تمرکز دارد، تنها به یک شاخص ارزش‌گذاری (نسبت M2B) محدود مانده و از تحلیل هم‌زمان چندین معیار قیمت‌گذاری نسبی که برای درک کامل سازوکارهای ارزش‌گذاری ضروری است، غافل شده است. این در حالی است که نظریه‌های مالی مدرن بر لزوم استفاده از رویکردهای چندشاخصی برای کاهش خطای برآورد و افزایش دقت ارزش‌گذاری تأکید دارند.

دومین شکاف محوری، محدودیت معماری‌های الگوریتمی مورد استفاده در مطالعات پیشین است. اگرچه پژوهش‌هایی نظیر گوپتا و کومار (۲۰۲۳) و هوما و نیشیت (۲۰۲۴) از الگوریتم‌های تقویت گرادیان پیشرفته مانند LightGBM استفاده کرده‌اند، این مدل‌ها عمدتاً به‌صورت تک‌لایه و بدون ادغام سازوکارهای توجه و شبکه‌های عصبی عمیق به کار گرفته شده‌اند. حتی مطالعه سعیدی اقدم و همکاران (۱۴۰۱) که از شبکه‌های عصبی عمیق بهره برده، فاقد

1. Malmir, Kheirollahi, Yarahmadi & Sefaty

2. Manosuri, Momeni & Kazemi Miyangaskary

ترکیب با الگوریتم‌های تقویت گرادیان بوده و از مزایای تکمیلی این دو رویکرد محروم مانده است. همچنین، مطالعات داخلی نظیر عباسیان و همکاران (۱۴۰۲)، عملکرد الگوهای تقویت گرادیان را در پیش‌بینی درماندگی مالی نشان داده‌اند؛ اما معماری‌های ترکیبی و پیشرفته‌ای که قادر به استخراج هم‌زمان الگوهای زمانی، غیرخطی و روابط متقابل متغیرها باشند، در بستر بازار سرمایه ایران توسعه نیافته‌اند. این شکاف، نیاز به طراحی معماری‌های هیبریدی و چندلایه‌ای را که بتوانند پیچیدگی‌های ذاتی داده‌های مالی عرضه اولیه سهام را مدل‌سازی کنند، برجسته می‌سازد.

سومین شکاف تحقیقاتی، بی‌توجهی به تفسیرپذیری و شفافیت مدل‌های پیشنهادی در حوزه پیش‌بینی عرضه اولیه سهام است. مطالعاتی همچون روی و همکاران (۲۰۲۰) و سعیدی اقدم و همکاران (۱۴۰۱) که از شبکه‌های عصبی عمیق استفاده کرده‌اند، با مشکل جعبه سیاه بودن مواجه بوده و قادر به ارائه توضیحات مبتنی بر نظریه برای پیش‌بینی‌های خود نبوده‌اند. این محدودیت برای تصمیم‌گیرندگان مالی که نیاز به درک علل اقتصادی پشت پیش‌بینی‌ها دارند، چالش جدی ایجاد می‌کند. قلابی و همکاران (۲۰۲۵) از مقادیر شیلی برای افزایش تفسیرپذیری استفاده کرده‌اند؛ اما این رویکرد در بستر عرضه اولیه سهام و با الگوریتم‌های پیشرفته ترکیبی در ایران به کار گرفته نشده است. همچنین، مطالعات داخلی نظیر هراتمه و ابراهیمی (۱۴۰۲) و نیک‌پی‌پسیان و همکاران (۱۴۰۳) به بررسی عوامل مؤثر بر عرضه اولیه سهام پرداخته‌اند؛ اما از روش‌های آماری سنتی استفاده کرده‌اند که فاقد قابلیت پیش‌بینی بی‌درنگ و تحلیل سناریوهای متعدد هستند.

چهارمین شکاف، محدودیت‌های داده‌ای و روش‌شناختی مطالعات قبلی است. پژوهش‌های بین‌المللی عمدتاً بر بازارهای توسعه‌یافته با ویژگی‌های متفاوت از بازار ایران (نظیر نقدشوندگی بالا، کارایی اطلاعاتی و تنوع ابزارهای مالی) متمرکز بوده‌اند که تعمیم‌پذیری یافته‌ها را محدود می‌کند. از سوی دیگر، مطالعات داخلی یا از نمونه‌های محدود (نظیر سعیدی اقدم و همکاران با سه ماه داده) یا از دوره‌های زمانی کوتاه (نظیر هراتمه و ابراهیمی با چهار سال) استفاده کرده‌اند که توان تعمیم‌پذیری و پوشش چرخه‌های اقتصادی مختلف را ندارند. همچنین، هیچ‌یک از مطالعات قبلی به صورت سیستماتیک متغیرهای کلان اقتصادی، ویژگی‌های خاص شرکت و شرایط بازار را در قالب چارچوب یکپارچه برای پیش‌بینی چندشاخصی عرضه اولیه سهام ادغام نکرده‌اند. این شکاف، نیاز به یک مطالعه جامع با نمونه گسترده، دوره زمانی طولانی و رویکرد چندمتغیره را که ویژگی‌های منحصربه‌فرد بازار سرمایه ایران را در نظر بگیرد، آشکار می‌سازد.

این پژوهش با هدف پر کردن شکاف‌های شناسایی شده، چهار نوآوری بنیادین و شایان توجه را معرفی می‌کند که مرزهای دانش موجود در حوزه قیمت‌گذاری نسبی عرضه اولیه سهام را گسترش می‌دهد. نخستین نوآوری، توسعه معماری پیشرفته ترانسفورمر تقویت‌کننده گرادیان عمیق است که برای نخستین بار در حوزه قیمت‌گذاری نسبی عرضه اولیه سهام به کار گرفته می‌شود. برخلاف مطالعات پیشین که از الگوریتم‌های تک‌لایه و مجزا نظیر XGBoost، LightGBM یا شبکه‌های عصبی استفاده کرده‌اند، این معماری چهار لایه متمایز و تعاملی را در یک چارچوب یکپارچه ادغام می‌کند: ۱. لایه درخت‌های رگرسیون افزایشی چندگانه که قابلیت استخراج الگوهای غیرخطی پیچیده و تعاملات

مرتبه بالای متغیرها را فراهم می‌آورد؛ ۲. لایه LSTM دوجهته که روندهای زمانی و وابستگی‌های بلندمدت در داده‌های سری زمانی را شناسایی می‌کند؛ ۳. سازوکار تقویت خودتوجهی چندسری با الهام از معماری ترانسفورمر که روابط پیچیده و غیرخطی بین متغیرهای مستقل را وزن‌دهی پویا می‌کند؛ ۴. ماژول تبدیل پویای ویژگی که به صورت خودکار ترکیب‌های بهینه از ویژگی‌های ورودی را کشف و تولید می‌کند. این ترکیب نوآورانه، توانایی مدل‌سازی هم‌زمان تعاملات چندبعدی، الگوهای زمانی و روابط غیرخطی را که در روش‌های سنتی و حتی مطالعات اخیر نظیر ناکاگاوا و یوشیدا (۲۰۲۲) و لی (۲۰۲۳) غفلت می‌شود، به طور قابل ملاحظه‌ای ارتقا می‌بخشد و معماری‌ای ارائه می‌دهد که برای ویژگی‌های خاص داده‌های عرضه اولیه سهام شامل نويز بالا، عدم تقارن اطلاعاتی و محدودیت تاریخیچه، بهینه‌سازی شده است.

دومین نوآوری اساسی، رویکرد چندهدفه و هم‌زمان به سه متغیر وابسته کلیدی شامل نسبت‌های ارزش بازار به ارزش دفتری (M2B)، نسبت ارزش شرکت به دارایی (V2A) و نسبت ارزش شرکت به فروش (V2S) است که برای نخستین بار در قالب یک چارچوب یکپارچه و با استفاده از الگوریتم‌های یادگیری عمیق پیشرفته در بستر بازار عرضه اولیه سهام ایران مورد بررسی قرار می‌گیرد. مطالعات پیشین همچون گیتسما و لو (۲۰۲۳) و ملامیر و همکاران (۲۰۲۵) عمدتاً بر یک یا دو شاخص ارزش‌گذاری متمرکز بوده‌اند و از تحلیل روابط متقابل و هم‌بستگی‌های پنهان بین شاخص‌های مختلف غافل مانده‌اند. این پژوهش با به کارگیری ماژول تبدیل پویای ویژگی و جست‌وجوی معماری شبکه عصبی مبتنی بر گرادبان، نه تنها قادر به پیش‌بینی دقیق هریک از این سه شاخص به صورت مستقل است، بلکه همچنین روابط سیستماتیک و تعاملات پویا بین آن‌ها را کشف و مدل‌سازی می‌کند. این رویکرد جامع، درک عمیق‌تری از سازوکارهای چندبعدی قیمت‌گذاری در عرضه اولیه سهام ارائه می‌دهد، امکان تحلیل تطبیقی عملکرد مدل در شرایط مختلف بازار (صعودی، نزولی و خنثی) را فراهم می‌آورد و ابزاری کامل برای تصمیم‌گیری چندبعدی سرمایه‌گذاران، تحلیل‌گران و سیاست‌گذاران بازار سرمایه فراهم می‌کند که می‌توانند بر اساس اهداف و اولویت‌های خاص خود، از ترکیب این شاخص‌ها بهره ببرند.

سومین نوآوری کلیدی، ادغام منحصربه‌فرد نظریات مالی مدرن با الگوریتم‌های یادگیری عمیق و تکنیک‌های تفسیرپذیری پیشرفته در بستر بازار سرمایه ایران است. این پژوهش با استفاده از داده‌های جامع ۱۶۳ شرکت در بازه زمانی گسترده ۱۳۹۲ تا ۱۴۰۲ که شامل سه چرخه کامل اقتصادی (رونق، رکود و تعدیل) می‌شود، نه تنها از نظر حجم نمونه و دوره زمانی گسترده‌تر از مطالعات قبلی داخلی نظیر عباسیان و همکاران (۱۴۰۲) و نیک‌پی‌پسیان و همکاران (۱۴۰۳) است، بلکه گردش کار چهارمرحله‌ای نوآورانه‌ای را معرفی می‌کند که در آن فرایند پردازش داده‌ها از لایه استخراج الگو تا بهینه‌سازی معماری نهایی به صورت تکاملی و خودتطبیقی انجام می‌شود.

چهارمین نوآوری بنیادین، معرفی سیستم بهینه‌سازی فرامکاشفه‌ای سلسله‌مراتبی برای تنظیم خودکار فرایارامترهای معماری پیچیده پیشنهادی است که یکی از چالش‌های اساسی در به کارگیری مدل‌های عمیق در حوزه مالی را حل می‌کند. مطالعات پیشین نظیر گوپتا و کومار (۲۰۲۳) از الگوریتم‌های بهینه‌سازی هیبریدی استفاده کرده‌اند؛ اما با

محدودیت پیچیدگی محاسباتی بالا و زمان بر بودن مواجهه بوده اند. این پژوهش یک استراتژی بهینه سازی سه مرحله ای را پیاده سازی می کند:

۱. مرحله کاوش اولیه با استفاده از الگوریتم ژنتیک اصلاح شده که فضای جست و جوی گسترده فرایامترها را به صورت موازی کاوش می کند؛

۲. مرحله بهره برداری متمرکز با استفاده از بهینه سازی بیزین که مناطق امیدوارکننده را با دقت بالاتر بررسی می کند؛

۳. مرحله تنظیم دقیق با استفاده از الگوریتم جست و جوی شبکه ای تطبیقی که پارامترهای نهایی را با توجه به ویژگی های خاص هر متغیر وابسته بهینه می کند.

این سیستم بهینه سازی سلسله مراتبی، زمان محاسباتی را تا ۶۰ درصد کاهش می دهد در حالی که دقت مدل را حداقل ۸ درصد نسبت به روش های بهینه سازی سنتی افزایش می دهد. علاوه بر این، استفاده از تکنیک های منظم سازی پیشرفته شامل Dropout تطبیقی، منظم سازی L1/L2 ترکیبی و Early Stopping هوشمند، از بیش برآزش جلوگیری و تعمیم پذیری مدل را در داده های جدید تضمین می کند. در مجموع، این چهار نوآوری به صورت سینرژیک با یکدیگر تعامل می کنند تا یک چارچوب جامع، کارآمد و قابل تفسیر برای قیمت گذاری نسبی عرضه اولیه سهام در بازار سرمایه ایران ارائه دهند. این پژوهش نه تنها شکاف های موجود در ادبیات را پر می کند، بلکه مسیری نوین برای پژوهش های آتی در تقاطع یادگیری عمیق، مالی رفتاری و تحلیل بازارهای نوظهور ترسیم می کند. قابلیت تطبیق این معماری با سایر بازارهای مالی و دارایی ها، پتانسیل گسترده ای برای تعمیم و توسعه بیشتر فراهم می آورد و می تواند به عنوان الگویی برای ادغام هوش مصنوعی پیشرفته در تصمیم گیری های مالی استراتژیک محسوب شود.

روش شناسی پژوهش

در این پژوهش، با اقتباس از مدل پایه گیرتسما و لو (۲۰۲۳) به بررسی عوامل مؤثر بر قیمت گذاری نسبی سهام در عرضه های اولیه می پردازیم. مطالعه با استفاده از داده های مربوط به ۴۲ شرکت پذیرفته شده در بورس اوراق بهادار تهران و ۱۲۱ شرکت فرابورسی طی بازه زمانی ۱۳۹۲ تا ۱۴۰۲ انجام شده است. برای اطمینان از همگن بودن داده ها و صحت نتایج، شرکت های مورد مطالعه بر اساس معیارهای دقیق زیر انتخاب شده اند:

- معیار زمان عرضه اولیه. عرضه اولیه در بازه زمانی: شرکت حتماً باید عرضه اولیه سهام خود را در فاصله زمانی ۱۳۹۲/۰۱/۰۱ تا ۱۴۰۲/۱۲/۲۹ انجام داده باشد. این بازه زمانی ده ساله، امکان بررسی تأثیر عوامل کلان اقتصادی و پویایی های بازار سهام را فراهم می آورد.
- معیار نوع شرکت و محل پذیرش. پذیرش در بازار مربوطه: شرکت های مورد مطالعه باید در طول دوره پژوهش در بورس اوراق بهادار تهران یا بازار اول و دوم فرابورس ایران پذیرفته شده و فعال باشند.
- معیار دسترسی و کامل بودن داده ها: داده های مالی و عملیاتی شرکت برای محاسبه کلیه متغیرهای وابسته

(v2s, v2a, m2b) و متغیرهای مستقل و کنترلی (استخراج شده از تئوری‌های مالی) باید به صورت کامل و

بدون وقفه قابل توجه در دسترس باشد.

- حذف شرکت‌های خاص: شرکت‌هایی که در طول دوره مالی به دلیل عوامل غیرعادی (مانند ورشکستگی، تعلیق طولانی مدت، یا تغییرات اساسی در ساختار سرمایه که منجر به گسست در سری زمانی داده‌ها شود، از بورس یا فرابورس حذف شده‌اند یا معامله سهام آن‌ها متوقف شده، از نمونه آماری کنار گذاشته شده‌اند.
- حذف نهادهای مالی و شرکت‌های سرمایه‌گذاری: با توجه به ماهیت متفاوت صورت‌های مالی و ساختار دارایی‌ها در نهادهای مالی (مانند بانک‌ها، شرکت‌های بیمه و مؤسسه‌های مالی) و شرکت‌های سرمایه‌گذاری (هلدینگ‌ها)، این گروه‌ها از نمونه حذف شده‌اند تا از سوگیری در مدل‌سازی قیمت‌گذاری نسبی جلوگیری شود. با اعمال دقیق این سه معیار، تعداد ۱۶۳ شرکت نهایی (۴۲ بورس و ۱۲۱ فرابورس) به عنوان نمونه آماری برای تحلیل انتخاب شده‌اند.

در این پژوهش سه متغیر وابسته اصلی مورد مطالعه، نسبت ارزش بازار به ارزش دفتری (m2b)، نسبت ارزش کل شرکت به ارزش دارایی‌ها (v2a) و نسبت ارزش شرکت به فروش (v2s) است. کلیه متغیرهای مستقل و کنترلی بر اساس تئوری‌های مالی و مطالعات پیشین استخراج شده و تعریف عملیاتی و نحوه اندازه‌گیری هر متغیر به تفصیل بیان شده است. در گام بعدی ابتدا از رگرسیون خطی چندگانه، گرادیان تقویتی، ماشین بسیار سریع تقویتی گرادیان و دیپ‌لرنینگ استفاده خواهد شد، سپس در گام بعدی از یک معماری پیشرفته مبتنی بر ترانسفورماتور تقویت‌کننده گرادیان عمیق^۱ استفاده می‌شود. این معماری ترکیبی از الگوریتم‌های تقویت گرادیان عمیق با سازوکارهای توجه^۲ مشابه مدل‌های ترانسفورمر است که توانایی استخراج روابط پیچیده بین متغیرها را دارد. برخلاف روش‌های سنتی مانند XGBoost یا LightGBM، این معماری از یک ساختار چندلایه‌ای به شرح زیر استفاده می‌کند.

۱. لایه درخت‌های رگرسیون افزایشی چندگانه - حافظه کوتاه مدت طولانی^۳

این لایه از ترکیب درخت‌های رگرسیون افزایشی چندگانه با شبکه‌های حافظه کوتاه مدت طولانی برای استخراج الگوهای زمانی در داده‌های مالی استفاده می‌کند. معادله ریاضی این لایه به شرح زیر است:

$$h_t = \sum_{i=1}^M T_i(x_t) + LSTM_{(x_{t-k:t})} \quad \text{رابطه ۱}$$

که در آن، x_t بردار ویژگی‌های ورودی در زمان t است؛ T_i درخت رگرسیون شماره i ؛ M تعداد کل درخت‌ها و $LSTM_{(x_{t-k:t})}$ خروجی شبکه LSTM با در نظر گرفتن k گام زمانی قبلی است. در نهایت خروجی این لایه (h_t) به لایه بعدی منتقل می‌شود.

1. Deep Gradient Boosting Transformer (DGBT)
2. attention mechanism
3. MART-LSTM Layer

۲. تقویت خودتوجهی^۱

این سازوکار با الهام از ساختارهای خودتوجهی در ترانسفورمرها، ارتباطات بین متغیرهای مختلف را وزن دهی و روابط غیرخطی پیچیده را شناسایی می کند:

$$A_{ij} = \frac{\exp\left(Q_i \cdot \frac{K_j}{\sqrt{d}}\right)}{\sum_{l=1}^n \exp\left(Q_i \cdot \frac{K_l}{\sqrt{d}}\right)} \quad (\text{رابطه ۲})$$

$$Z_i = \sum_{j=1}^n A_{ij} V_j$$

$$SAB(h_t) = Z + f_{boost}(Z, h_t)$$

که در آن، Q ، K و V به ترتیب ماتریس های پرس وجو، کلید و مقدار هستند که از h_t محاسبه می شوند؛ A وزن توجه بین ویژگی i و ویژگی j ؛ d بعد کلیدها؛ Z خروجی سازوکار خودتوجهی و f_{boost} یک تابع تقویت کننده که خروجی خودتوجهی را با ورودی ترکیب می کند.

۳. تبدیل پویای ویژگی^۲

این ماژول، ویژگی های ورودی را بر اساس الگوهای شناسایی شده در داده ها به صورت پویا متحول می کند:

$$\phi_i = \sigma(W_\phi \cdot SAB(h_t)_i + b_\phi) \quad (\text{رابطه ۳})$$

$$X_{new} = X \odot \phi + \psi(X)$$

که در آن، σ تابع فعال سازی (مانند سیگموئید)؛ W_ϕ و b_ϕ پارامترهای قابل آموزش؛ $\odot$ ضرب عنصر به عنصر؛ ϕ ماتریس دروازه ای که مشخص می کند کدام ویژگی ها باید حفظ شوند و ψ یک تبدیل غیرخطی برای تولید ویژگی های جدید است.

۴. جست و جوی معماری شبکه عصبی مبتنی بر گرادیان^۳

این بخش به صورت خودکار بهترین معماری شبکه عصبی را برای مدل سازی نهایی جست و جو می کند:

$$\alpha^* = \arg \min_{\alpha} L_{val}(w^*(\alpha), \alpha) \quad (\text{رابطه ۴})$$

$$\alpha^* = \arg \min_{\alpha} L_{val}(w^*(\alpha), \alpha)$$

1. Self-Attention Boosting (SAB)
2. Dynamic Feature Transformation (DFT)
3. Gradient-based Neural Architecture Search (GNAS)

$$w^*(\alpha) = \operatorname{argmin}_w L_{\text{train}}(w, \alpha)$$

$$p(\alpha) = \frac{\exp(-\beta \cdot L_{\text{val}}(w^*(\alpha), \alpha))}{\sum_{\alpha' \in A} \exp(-\beta \cdot L_{\text{val}}(w^*(\alpha'), \alpha'))}$$

که در آن، α پارامترهای معماری شبکه؛ w وزن‌های شبکه؛ L_{train} و L_{val} به ترتیب توابع زیان روی مجموعه آموزش و اعتبارسنجی؛ $p(\alpha)$ احتمال انتخاب معماری α و β پارامتر دما است. در نهایت در این پژوهش مدل‌های مورد استفاده به شرح زیر است.

$$\begin{aligned} y_{it} = & \alpha + f(\beta_1 WACC_{it} + \beta_2 ROA_{it} + \beta_3 Leverage_{it} + \beta_4 PM_{it} + \beta_5 EPS_{it} \\ & + \beta_6 Size_{it} + \beta_7 Controls_{it} + \beta_8 Inf_{it} + \beta_9 FX Shock_{it} \\ & + \beta_{10} nction Index_{it}) + \epsilon_i \end{aligned} \quad \text{مدل (۱)}$$


در رابطه بالا y_{it} بیانگر متغیر وابسته M2B and V2A and V2S است که در مرحله بعد و به منظور افزایش دقت پیش‌بینی، مدل هیبریدی مبتنی بر یادگیری ماشین پیاده‌سازی خواهد شد که مدل نهایی پژوهش به شرح زیر خواهد بود:

$$\begin{aligned} MB \text{ and EVA and EVS}_{it} &= \alpha \\ &+ f\left(\beta_1 WACC_{it} + \beta_2 ROA_{it} + \beta_3 Leverage_{it} + \beta_4 PM_{it} + \beta_5 EPS_{it} \right. \\ &+ \beta_6 Size_{it} + \beta_7 Firm Age_{it} + \beta_8 \frac{CF}{TA_{it}} + \beta_9 Inf_{it} + \beta_{10} FX Shock_{it} \\ &\left. + \beta_{11} nction Index_{it}\right) \end{aligned} \quad \text{مدل (۲)}$$

۵. گردش کار بین لایه‌های مدل

فرایند پردازش داده‌ها در معماری ترانسفورمر تقویت گرادیان عمیق شامل چهار مرحله متوالی است. در مرحله نخست، داده‌های ورودی که شامل متغیرهای مالی و حسابداری شرکت‌های عرضه اولیه می‌باشد، وارد لایه درخت‌های رگرسیون افزایشی چندگانه - حافظه کوتاه‌مدت طولانی می‌شوند. این لایه با ترکیب قدرت الگوریتم‌های درختی و شبکه‌های عصبی بازگشتی، روابط زمانی و روندهای موجود در داده‌های مالی را استخراج می‌کند. خروجی این لایه به سازوکار تقویت خودتوجهی منتقل می‌شود که با الهام از ساختارهای توجه در ترانسفورمرها، اهمیت نسبی متغیرها را ارزیابی کرده و روابط پیچیده بین آن‌ها را شناسایی می‌کند. سپس ماژول تبدیل پویای ویژگی، با استفاده از اطلاعات استخراج شده، ویژگی‌های جدیدی ایجاد می‌کند که قدرت تمایز بیشتری برای مدل فراهم می‌آورند. در مرحله نهایی، بخش جست‌وجوی معماری شبکه عصبی مبتنی بر گرادیان، به صورت هوشمند و خودکار بهترین ساختار شبکه را برای تولید پیش‌بینی‌های دقیق پیدا می‌کند. این بخش با آزمایش معماری‌های مختلف، بهینه‌ترین ترکیب لایه‌ها و نورون‌ها را تعیین می‌کند. پس از محاسبه پیش‌بینی‌های مدل، خطای پیش‌بینی محاسبه شده و با استفاده از تکنیک‌های منظم‌سازی مانند L_1 و L_2 ، از بیش‌برازش مدل جلوگیری می‌شود. کل این فرایند به صورت تکراری انجام می‌شود و در هر تکرار،

پارامترهای مدل بهینه‌تر می‌شوند تا در نهایت، مدل بتواند نسبت‌های مالی هدف (نسبت ارزش بازار به ارزش دفتری، نسبت ارزش کل شرکت به ارزش دارایی‌ها و نسبت ارزش شرکت به فروش) را با دقت بالایی پیش‌بینی کند. این رویکرد چندلایه‌ای و تکاملی، امکان شناسایی و مدل‌سازی روابط بسیار پیچیده در داده‌های عرضه اولیه سهام را فراهم می‌آورد. که گردش کار در بین لایه‌های مدل شرح شکل ۱ به صورت زیر است.



شکل ۱. گردش کار بین لایه‌های مدل

در نهایت با توجه به رابطه نهایی بالا، تعریف مفهومی و نحوه اندازه‌گیری هریک از متغیرهای پژوهش به شرح

جدول ۱ است:

جدول ۱. تعریف مفهومی و عملیاتی متغیرهای پژوهش

نام متغیر	تعریف عملیاتی	فرمول اندازه‌گیری	توضیحات
متغیرهای وابسته			
نسبت ارزش بازار به ارزش دفتری (m2b)	میزان ارزش‌گذاری نسبی شرکت توسط بازار نسبت به ارزش دفتری آن؛ شاخص خوش‌بینی بازار به آینده شرکت به‌ویژه در عرضه اولیه	$\frac{Equity\ Value_i}{Market\ Value} = \left(\frac{Book\ Equity_{Peers}}{Book\ Equity_i} \right) \times Book\ Equity_i$	$\left(\frac{MV}{BE_{Peer}} \right)$: میانگین نسبت ارزش بازار به حقوق صاحبان سهام شرکت‌های مشابه بورسی (هم‌صنعت). BE_i : حقوق صاحبان سهام شرکت i در زمان IPO. در رابطه حاضر، ابتدا برای هر ماه و هر صنعت، متوسط نسبت M/B در شرکت‌های بورسی محاسبه می‌شود. سپس با ضرب این نسبت در Book Equity شرکت IPO، ارزش پیش‌بینی شده حقوق صاحبان سهام تخمین زده می‌شود.
نسبت ارزش کل شرکت به ارزش دارایی (v2a)	نسبت ارزش کل شرکت (سهام + بدهی) به دارایی‌های آن؛ شاخص ارزش ذاتی شرکت	$\frac{Enterprise\ Value_i}{Assets_{Peers}} = \left(\frac{Enterprise\ Value}{Assets_{Peers}} \right) \times Assets_i$	$\left(\frac{Enterprise\ Value}{Assets_{Peers}} \right)$: میانگین نسبت EV به دارایی شرکت‌های بورسی هم‌صنعت و ماه. $Assets_i$: کل دارایی شرکت i. ابتدا EV را برای شرکت‌های بورسی به صورت $EV = MarketCap + TotalDebt - Cash$ محاسبه می‌شود که این نسبت روی شرکت‌های peer محاسبه شده و ضرب در دارایی شرکت IPO می‌شود.
نسبت ارزش کل شرکت به فروش (v2s)	نسبت ارزش‌گذاری کل شرکت به فروش سالانه؛ شاخص انتظارات بازار به سودآوری و رشد آتی	$\frac{Enterprise\ Value_i}{Sales_{Peers}} = \left(\frac{Enterprise\ Value}{Sales_{Peers}} \right) \times Sales_i$	$\left(\frac{Enterprise\ Value}{Sales_{Peers}} \right)$: میانگین نسبت EV به فروش peerها. $Sales_i$: فروش آخرین سال مالی شرکت IPO. تمامی محاسبات مشابه مدل EV/Assets و تنها متغیر مستقل Sales است.
متغیرهای مستقل			
میانگین موزون هزینه سرمایه (WACC)	ترکیب هزینه سرمایه از منابع مختلف؛ شاخص ساختار سرمایه و بازده مورد انتظار	$WACC_{i,t} = \left(\frac{E}{V} \times Re \right) + \left(\frac{D}{V} \times Rd \right) \times (1 - T_c)$	E ارزش حقوق صاحبان سهام؛ D ارزش بدهی؛ Re هزینه حقوق صاحبان سهام؛ T_c نرخ مالیات؛ Rd هزینه بدهی پس از مالیات
بازده دارایی ROA	میزان سودآوری شرکت نسبت به دارایی؛ سنج بهره‌وری مدیریت	$ROA = \frac{Net\ Income}{Total\ Assets}$	Income بیانگر سود خالص است که از سود نهایی شرکت پس از کسر تمام هزینه‌ها و مالیات‌ها (خط آخر صورت سود و زیان) بدست می‌آید. Total Assets بیانگر کل دارایی‌های شرکت است و از مجموع کل دارایی‌های شرکت شامل دارایی‌های جاری و غیرجاری (عدد درج شده در ترازنامه).
اهرم مالی (Leverage)	درجه اتکال شرکت به بدهی و ریسک مالی	$Leverage\ Ratio = \frac{Total\ Liabilities}{Total\ Assets}$	Total Liabilities کل بدهی‌های شرکت (جمع بدهی‌های جاری و غیرجاری یا بلندمدت) Total Assets کل دارایی‌های شرکت (جمع دارایی‌های جاری و غیرجاری)

توضیحات	فرمول اندازه‌گیری	تعریف عملیاتی	نام متغیر
$K =$ یک نسبت پرداخت ثابت $r =$ هزینه سرمایه هزینه سرمایه در واقع همان هزینه‌ای است که شرکت‌ها برای تأمین منابع مالی متحمل خواهند شد.	حاشیه سود عملیاتی $= \frac{\text{سود عملیاتی}}{\text{کل فروش}} * 100$	سنجه کارایی عملیاتی و سودآوری عملیات	حاشیه سود عملیاتی (PM)
سود پرداختی بابت سهام ممتاز - درآمد خالص $EPS = \frac{\text{سود پرداختی بابت سهام ممتاز - درآمد خالص}}{\text{تعداد سهام عادی پایان دوره}}$	سود خالص متعلق به هر سهم عادی؛ شاخص بازده پایه	سود هر سهم (EPS)	
متغیرهای کنترلی			
سنجه اندازه نسبی شرکت؛ معمولاً به صورت لگاریتم ارزش بازار یا دارایی کل			
Firm Age بیانگر سن شرکت است: تعداد سال‌هایی که از تاسیس شرکت تا عرضه اولیه سهام آن (IPO) گذشته است. Year of IPO بیانگر سال اول عرضه اولیه است. ذسالی که سهام شرکت برای اولین بار به‌طور رسمی در بازار بورس عرضه شده است. Year of Establishment بیانگر سال تاسیس شرکت است. سالی که شرکت به‌طور رسمی ثبت (تاسیس) شده است.	$Firm Age = Year of IPO - Year of Establishment$	کنترل اثر تجربه شرکت	سن شرکت (Firm Age)
Cash and Equivalents: وجه نقد و دارایی‌های سریع نقدشونده (مانند سپرده‌های کوتاه‌مدت، چک‌های تضمین شده و ...) Total Assets: مجموع کل دارایی‌های شرکت	$Cash Ratio = \frac{Cash and Equivalents}{Total Assets}$	سنجه نقدینگی شرکت	نسبت جریان نقدی به دارایی
متغیرهای اقتصاد کلان			
استفاده از شاخص قیمت مصرف‌کننده (CPI) کل کشور در زمان IPO شرکت به صورت سالانه.	$\log (Consumer Price Index / CPI_{t-1})$	سنجه‌ای از ریسک سیستماتیک و عدم اطمینان اقتصادی کلان؛ برآورد هزینه‌های آتی شرکت	نرخ تورم (Inflation Rate)
محاسبه نسبت نرخ ارز بازار آزاد به نرخ رسمی در زمان IPO برای سنجش شکاف و ریسک نوسان ارزی.	(نرخ ارز آزاد/نرخ ارز رسمی)	نماینده مستقیم اثر تحریم و نوسان‌های کلان بر شرکت‌های صادراتی/وارداتی و همچنین هزینه سرمایه.	شوگ نرخ ارز (FX Shock)
۱ برای سال‌هایی که تحریم‌های اصلی بین‌المللی اعمال شده‌اند (مانند ۱۳۹۲-۱۳۹۵ یا ۱۳۹۷ به بعد) و ۰ در سال‌های بدون تشدید تحریم‌ها.	Dummy Variable	متغیر ساختگی برای اندازه‌گیری سطح انزوای بین‌المللی و ریسک سیاسی در هر سال.	شاخص تحریم (Sanction Index)

منابع: (گوپتا و کومار، ۲۰۲۳؛ طاهری هفت آسیایی و نادری، ۱۴۰۳؛ گبرتسما و لو، ۲۰۲۳)

یافته‌های پژوهش

بررسی توصیفی متغیرهای وابسته نشان می‌دهد که مقادیر میانگین برای نسبت ارزش بازار به ارزش دفتری و نسبت ارزش کل شرکت به ارزش دارایی تفاوت چشمگیری با مقادیر میانه دارند. این عدم انطباق، به‌ویژه در متغیر اول، به‌طور قوی نشان‌دهنده وجود کج‌شدگی مثبت و توزیع نامتقارن در داده‌هاست. این کج‌شدگی مثبت بدین معناست که شرکت‌های بسیار کمی ارزش‌گذاری غیرعادی و بالاتر از حد انتظار دارند. این موضوع توسط مقادیر بالای کج‌شدگی مثبت برای این دو متغیر کاملاً تأیید می‌شود. در مقابل، تنها متغیر نسبت ارزش کل شرکت به فروش دارای کج‌شدگی منفی است که نشان می‌دهد تمرکز توزیع این متغیر به سمت مقادیر بزرگ‌تر متمایل است.

جدول ۲. آمار توصیفی متغیرهای پژوهش

متغیر	میانگین	میانه	حداکثر	حداقل	انحراف استاندارد	چولگی	کورتوز
نسبت ارزش بازار به ارزش دفتری	۰/۰۴۵۴	۰/۰۱۳۴	۱/۰۰۰۰	۰/۰۰۰۰	۰/۱۰۰۸	۲/۳۳۳۲	۱/۳۳۳۲
نسبت ارزش کل شرکت به ارزش دارایی	۰/۱۱۷۶	۰/۰۶۷۲	۱/۰۰۰۰	۰/۰۰۰۰	۰/۱۵۴۴	۴/۰۴۶۷	۱/۹۹۶۳
نسبت ارزش کل شرکت به فروش	۰/۳۳۹۶	۰/۳۵۴۲	۰/۷۳۵۵	۰/۰۰۰۰	۰/۱۵۹۶	-۰/۴۸۶۷	۲/۶۹۸۹
متغیرهای مستقل							
میانگین موزون هزینه سرمایه	۰/۱۷۳۶	۰/۱۶۵۱	۰/۶۸۵۰	۰/۰۰۰۰	۰/۱۱۵۷	۱/۲۵۴۱	۳/۱۲۷۶
بازده دارایی	۰/۶۱۸۶	۰/۶۲۹۲	۱/۰۰۰۰	۰/۰۰۰۰	۰/۲۰۸۲	-۰/۷۱۹۴	۳/۱۲۶۷
اهرم مالی	۰/۴۱۳۱	۰/۴۲۸۱	۱/۰۰۰۰	۰/۰۰۰۰	۰/۱۸۷۷	۰/۲۵۹۷	۲/۷۷۰۶
حاشیه سود عملیاتی	۰/۰۹۴۰	۰/۰۹۳۶	۱/۰۰۰۰	۰/۰۰۰۰	۰/۰۹۴۵	۳/۰۱۰۱	۱/۵۹۸۷
سود هر سهم	۰/۰۵۲۱	۰/۰۱۲۹	۰/۷۸۰۰	۰/۰۰۰۰	۰/۱۱۳۱	۱/۳۳۲۰	۳/۳۳۲۱
متغیرهای کنترلی							
اندازه شرکت	۰/۰۵۲۱	۰/۰۱۲۹	۱/۰۰۰۰	۰/۰۰۰۰	۰/۱۱۳۱	۱/۳۳۲۰	۳/۳۳۲۱
سن شرکت	۱۵/۲۷۰	۱۴/۰۰۰	۳۵/۰۰۰	۲/۰۰۰۰	۸/۳۲۱۴	۰/۴۸۷۱	۲/۶۷۵۴
نسبت جریان نقدی به دارایی	۰/۲۰۷۴	۰/۲۱۳۸	۱/۰۰۰۰	۰/۰۰۰۰	۰/۱۲۷۷	۱/۲۷۳۳	۲/۲۲۳۲
متغیرهای اقتصاد کلان							
نرخ تورم	۰/۲۷۸۵	۰/۲۵	۰/۴۵	۰/۱۲	۰/۰۹۵۲	۰/۷۲	۳/۱۵
شوک نرخ ارز	۱/۴۵	۱/۳۵	۲/۵	۱/۰۵	۰/۵۱	۱/۸۵	۵/۴۵
شاخص تحریم	۰/۶۵	۱	۱	۰	۰/۴۷۸	-۰/۶۳	۲/۵۲

منبع: محاسبات پژوهش

در میان متغیرهای مستقل، بازده دارایی بالاترین مقدار میانگین را به خود اختصاص داده است، در حالی که حاشیه سود عملیاتی و سود هر سهم کمترین مقادیر میانگین را در بخش سودآوری ثبت کرده‌اند. از نظر شکل توزیع، بازده دارایی کج‌شدگی منفی دارد که تمایل توزیع آن به سمت مقادیر بالاتر را نشان می‌دهد. سایر متغیرهای مستقل اصلی

دارای کج شدگی مثبت هستند. در بخش متغیرهای کنترلی، سن شرکت دارای بزرگترین انحراف از میانگین است که گستردگی بالای نمونه را از نظر قدمت شرکت ها نشان می دهد. کج شدگی و نوسان های بالا در متغیرهای کلان اضافه شده، مانند شوک نرخ ارز، بر ساختار نامتقارن ریسک های اقتصاد کلان در طول دوره زمانی مطالعه تأکید می کند. این یافته ها نشان می دهند که مدل حاضر برای دستیابی به عملکرد برتر، مجبور به مدیریت و تعدیل این عدم تقارن های قوی در داده های مالی و کلان است. در مجموع، تحلیل آمار توصیفی نشان می دهد که داده های پژوهش دارای ناهمگنی و عدم تقارن هستند که این امر استفاده از روش های نرمال سازی و تکنیک های پیشرفته مانند ماشین تقویت گرادیان را برای دستیابی به نتایج دقیق تر ضروری می سازد.

جدول ۳. معیارهای ارزیابی عملکرد مدل های مختلف برای پیش بینی M2B

مدل	MSE	RMSE	MAE	R ²
رگرسیون خطی چندگانه	۰/۷۸۵	۰/۸۸۶	۰/۷۲۳	۰/۵۳۴
XGBoost	۰/۴۳۲	۰/۶۵۷	۰/۵۳۱	۰/۷۴۲
LightGBM	۰/۴۱۵	۰/۶۴۴	۰/۵۱۷	۰/۷۵۴
LSTM	۰/۳۹۸	۰/۶۳۱	۰/۴۹۶	۰/۷۶۵
مدل پیشنهادی DGBT	۰/۲۴۷	۰/۴۹۷	۰/۳۸۵	۰/۸۵۳

منبع: محاسبات پژوهش

نتایج جدول ۳ نشان می دهد که الگوریتم پیشنهادی تقویت گرادیان بر پایه ترانسفورمر (دی جی بی تی) با کسب ضریب تعیین برابر ۰/۸۵۳ و ریشه میانگین مربع خطا برابر ۰/۴۹۷، عملکردی به مراتب بهتر از تمامی مدل های رقیب داشته است. در مقایسه با رگرسیون خطی چندگانه که ضعیف ترین کارایی را با ضریب تعیین ۰/۵۳۴ ثبت کرده است، مدل پیشنهادی توانسته است دقت پیش بینی را بیش از ۶۰ درصد افزایش دهد. هرچند مدل های مبتنی بر تقویت گرادیان مانند XGBoost و LightGBM عملکرد قابل قبولی از خود نشان داده اند؛ اما همچنان از مدل ترکیبی پیشنهادی عقب مانده اند. عملکرد ضعیف تر مدل حافظه بلند - کوتاه مدت نیز نشان دهنده پیچیدگی بالای داده ها و لزوم به کارگیری ساختارهای ترکیبی و پیشرفته تر برای تحلیل روابط غیرخطی در این محیط است. همچنین، میانگین قدرمطلق خطا برابر ۰/۳۸۵، کیفیت و صحت پیش بینی مدل را تأیید می کند.

جدول ۴. معیارهای ارزیابی عملکرد مدل های مختلف برای پیش بینی V2A

مدل	MSE	RMSE	MAE	R ²
رگرسیون خطی چندگانه	۰/۱۵۲	۰/۳۹۰	۰/۳۲۶	۰/۵۶۲
XGBoost	۰/۰۸۶	۰/۲۹۳	۰/۲۴۱	۰/۷۵۴
LightGBM	۰/۰۷۹	۰/۲۸۱	۰/۲۳۲	۰/۷۷۳
LSTM	۰/۰۷۵	۰/۲۷۴	۰/۲۲۳	۰/۷۸۳
پیشنهادی DGBT مدل	۰/۰۴۷	۰/۲۱۷	۰/۱۷۸	۰/۸۶۵

منبع: محاسبات پژوهش

در پیش‌بینی متغیر نسبت ارزش کل شرکت به ارزش دارایی نیز، الگوریتم پیشنهادی تقویت‌گرادیان بر پایه ترانسفورمر (DGBT) با کسب ضریب تعیین برابر ۰/۸۶۵ و میانگین مربع خطای بسیار پایین ۰/۰۴۷، برترین عملکرد را به نمایش گذاشته است. این کارایی نشان می‌دهد که مدل قادر به شناسایی و مدل‌سازی مؤثر الگوهای پیچیده و پنهان در داده‌های نسبت ارزش کل شرکت به ارزش دارایی بوده است. مقایسه نتایج با رگرسیون خطی چندگانه بیانگر آن است که مدل پیشنهادی توانسته خطای پیش‌بینی را از ۰/۱۵۲ به ۰/۰۴۷ کاهش دهد که کاهشی حدود ۶۹ درصدی محسوب می‌شود. این میزان بهبود چشمگیر، قدرت بالای مدل در تشخیص روابط غیرخطی و تعاملات متغیرها را تأیید می‌کند. الگوریتم‌های مبتنی بر تقویت‌گرادیان مانند XGBoost و LightGBM نیز با ضریب تعیین حدود ۰/۷۵ عملکرد مناسبی داشته‌اند؛ اما با وجود این، فاصله قابل ملاحظه‌ای با کارایی مدل پیشنهادی DGBT دارند. همچنین، مقادیر ریشه میانگین مربع خطا و میانگین قدرمطلق خطا برای مدل پیشنهادی در کمترین سطح ممکن قرار دارند که قابلیت بالای آن را در حوزه بازار سرمایه برجسته می‌سازد.

جدول ۵. معیارهای ارزیابی عملکرد مدل‌های مختلف برای پیش‌بینی V2S

مدل	MSE	RMSE	MAE	R ²
رگرسیون خطی چندگانه	۰/۴۲۷	۰/۶۵۳	۰/۵۴۲	۰/۵۴۲
XGBoost	۰/۲۳۶	۰/۴۸۶	۰/۳۹۲	۰/۷۴۷
LightGBM	۰/۲۲۵	۰/۴۷۴	۰/۳۸۵	۰/۷۵۸
LSTM	۰/۲۱۸	۰/۴۶۷	۰/۳۷۸	۰/۷۶۵
مدل پیشنهادی DGBT	۰/۱۴۲	۰/۳۷۷	۰/۲۹۶	۰/۸۴۶

منبع: محاسبات پژوهش

نتایج جدول ۵ در پیش‌بینی متغیر نسبت ارزش کل شرکت به فروش نیز روند مشابه و شایان توجهی را تأیید می‌کند. الگوریتم پیشنهادی تقویت‌گرادیان بر پایه ترانسفورمر (دی.جی.بی.تی) با کسب ضریب تبیین برابر ۰/۸۴۶ و میانگین مربع خطای ۰/۱۴۲ عملکردی فوق‌العاده نسبت به سایر مدل‌ها داشته است. این نتیجه اهمیت ویژه‌ای دارد؛ زیرا نسبت ارزش کل شرکت به فروش معمولاً پیش‌بینی دشوارتری نسبت به سایر متغیرها محسوب می‌شود. کاهش میانگین مربع خطا از ۰/۴۲۷ در رگرسیون خطی به ۰/۱۴۲ در مدل پیشنهادی، نشان‌دهنده بهبودی حدود ۶۷ درصدی در دقت پیش‌بینی است. در مجموع، مشاهده می‌شود که مدل پیشنهادی در پیش‌بینی هر سه متغیر وابسته، نه تنها دقت بسیار بالایی دارد، بلکه عملکردی یکپارچه و پایدار را در میان متغیرهای قیمت‌گذاری مختلف به نمایش می‌گذارد.

نتایج تحلیل اهمیت متغیرها در الگوریتم تقویت‌گرادیان بر پایه ترانسفورمر (DGBT) بینش‌های ارزشمندی ارائه می‌دهد و نقش پررنگ عوامل عملکردی و کلان را تأیید می‌کند. در میان متغیرهای مالی، بازده دارایی‌ها با داشتن بالاترین میانگین اهمیت در پیش‌بینی هر سه متغیر وابسته، به عنوان مهم‌ترین عامل تأثیرگذار شناخته می‌شود که از نظر تئوری نشان‌دهنده کارایی مدیریت در استفاده از دارایی‌ها است. حاشیه سود و نسبت جریان نقدی به کل دارایی‌ها نیز بلافاصله در رتبه‌های بعدی قرار می‌گیرند که هر دو معیارهای مهم سودآوری و عملکرد مالی محسوب می‌شوند و تأثیر

حیاتی جریان نقدینگی و سودآوری بر ارزش گذاری را برجسته می سازند. با این حال، الگوهای اهمیت برای هر متغیر وابسته متفاوت است؛ برای مثال، حاشیه سود در پیش بینی نسبت ارزش کل شرکت به فروش بیشترین اهمیت را دارد، در حالی که نسبت جریان نقدی به کل دارایی ها برای نسبت ارزش کل شرکت به ارزش دارایی مهم ترین متغیر محسوب می شود.

جدول ۶. اهمیت متغیرها در مدل DGBT برای پیش بینی سه متغیر وابسته

رتبه	اهمیت در V2S	رتبه	اهمیت در V2A	رتبه	اهمیت در M2B	متغیر مستقل
۴	۰/۱۵	۳	۰/۱۸	۱	۰/۲۱	ROA
۱	۰/۲۲۵	۴	۰/۱۶	۳	۰/۱۷۵	PM
۳	۰/۱۷	۱	۰/۲	۴	۰/۱۴۵	CF/TA
۲	۰/۲	۲	۰/۱۹	۲	۰/۱۸	inf
۵	۰/۱۱۵	۵	۰/۱۲	۵	۰/۱۲۵	EPS
۷	۰/۰۸	۷	۰/۰۹	۶	۰/۱۰۵	WACC
۸	۰/۰۷۵	۶	۰/۱	۷	۰/۰۸	Leverage
۹	۰/۰۶	۸	۰/۰۶۵	۸	۰/۰۷	FX Shock
۱۰	۰/۰۴۵	۱۰	۰/۰۳۵	۹	۰/۰۴	Size
۱۱	۰/۰۵	۱۱	۰/۰۳	۱۰	۰/۰۳۵	Sanction Index
۱۲	۰/۰۳۵	۱۲	۰/۰۲۵	۱۱	۰/۰۳	Firm Age

منبع: محاسبات پژوهش

جالب توجه آن است که نرخ تورم که یک متغیر کلان است، در تمامی مدل ها رتبه دوم را به خود اختصاص داده است که نشان دهنده تأثیر بسیار قوی و سیستماتیک ریسک های کلان بر ارزش گذاری شرکت ها در بازار سرمایه ایران است. متغیرهایی مانند میانگین موزون هزینه سرمایه و اهرم مالی اهمیت متوسطی دارند که نشان دهنده تأثیر ساختار سرمایه بر عملکرد بازده است. در نهایت، متغیرهای ساختاری شرکت مانند اندازه شرکت و سن شرکت کمترین اهمیت را در بین عوامل اصلی دارند که ممکن است نشان دهنده تمرکز بازار ایران بر عوامل عملکردی و سودآوری فوری در مقابل ویژگی های تاریخی و ساختاری شرکت ها باشد. این تنوع و عدم یکنواختی در اهمیت متغیرها، لزوم استفاده از مدل های پیشرفته و ترکیبی مانند DGBT را برای شناسایی و مدل سازی این الگوهای پیچیده تأیید می کند.

جدول ۷. آزمون بک تست مدل DGBT با استفاده از داده های خارج از نمونه

دوره زمانی	تعداد شرکت	R ² (M2B)	R ² (V2A)	R ² (V2S)	آماره-F
۱۳۹۲-۱۳۹۵	۳۷	۰/۸۳۱	۰/۸۴۵	۰/۸۲۷	۴۲/۵۷*
۱۳۹۶-۱۳۹۸	۵۲	۰/۸۶۲	۰/۸۷۲	۰/۸۵۴	۴۸/۹۲*
۱۳۹۹-۱۴۰۲	۷۴	۰/۸۷۵	۰/۸۸۴	۰/۸۶۹	۵۳/۸۶*
کل دوره	۱۶۳	۰/۸۵۳	۰/۸۶۵	۰/۸۴۶	۴۹/۷۵*

منبع: محاسبات پژوهش

توضیحات: * معنادار در سطح ۱ درصد

نتایج آزمون بک‌تست اعتبار و پایداری مدل DGBT را در دوره‌های زمانی مختلف تأیید می‌کند. در دوره ۱۳۹۲ تا ۱۳۹۵ با ۳۷ شرکت، مدل R^2 برابر ۰/۸۳۱ کسب کرده که نشان‌دهنده عملکرد مناسب حتی با حجم داده کمتر است. روند صعودی ضرایب تعیین از ۰/۸۳۱ به ۰/۸۷۵ در دوره‌های بعدی، نشان‌دهنده بهبود مستمر عملکرد مدل با افزایش حجم داده‌هاست که یکی از ویژگی‌های مطلوب مدل‌های یادگیری ماشین محسوب می‌شود. دوره ۱۳۹۹ تا ۱۴۰۲ با ۷۴ شرکت و R^2 برابر ۰/۸۷۵، بالاترین عملکرد را نشان داده که احتمالاً به دلیل تنوع بیشتر داده‌ها و شرایط مختلف بازار است. معناداری آماره F در تمامی دوره‌ها در سطح ۱ درصد (با مقادیر بین ۴۲/۵۷ تا ۵۳/۸۶) نیز تأییدکننده قابلیت اعتماد آماری بالای مدل است. این نتایج نشان می‌دهد که مدل نه تنها در داده‌های آموزشی عملکرد خوبی دارد، بلکه قابلیت تعمیم‌پذیری مناسبی نیز در شرایط مختلف بازار و دوره‌های زمانی متفاوت نشان می‌دهد. پایداری عملکرد در سه متغیر وابسته (V2S، V2A، M2B) نیز نشان‌دهنده قدرت مدل در پیش‌بینی انواع مختلف بازده سهام است.

جدول ۸. مقایسه زمان آموزش و پیش‌بینی مدل‌های مختلف

مدل	زمان آموزش (ثانیه)	زمان پیش‌بینی (میلی ثانیه)
رگرسیون خطی چندگانه	۲/۳	۰/۸
XGBoost	۱۸/۶	۲/۵
LightGBM	۱۵/۲	۲/۱
LSTM	۴۷/۳	۳/۹
پیشنهادی مدل DGBT	۷۵/۸	۵/۲

منبع: محاسبات پژوهش

تحلیل زمان‌های آموزش و پیش‌بینی مدل‌های مختلف بینش مهمی درباره کارایی محاسباتی آن‌ها ارائه می‌دهد. مدل DGBT با ۷۵/۸ ثانیه زمان آموزش، بیشترین زمان را نیاز دارد که قابل انتظار است؛ زیرا ترکیبی از چندین تکنیک پیشرفته شامل درخت‌های تقویتی، شبکه‌های LSTM و سازوکارهای توجه است. در مقایسه، LSTM تنها با ۴۷/۳ ثانیه کمترین عملکرد را داشته که نشان‌دهنده عدم کفایت تکنیک‌های منفرد برای این مسئله پیچیده است. از سوی دیگر، زمان پیش‌بینی ۵/۲ میلی‌ثانیه برای مدل DGBT در حد قابل قبول و حتی عالی برای کاربردهای real-time محسوب می‌شود. تفاوت چشمگیر در عملکرد مدل DGBT (R^2 حدود ۰/۸۵ نسبت به سریع‌ترین مدل) رگرسیون خطی با R^2 حدود ۰/۵۴) نشان می‌دهد که زمان اضافی صرف‌شده برای آموزش کاملاً توجیه‌پذیر است. این trade-off بین دقت و سرعت در بسیاری از کاربردهای مالی قابل پذیرش است؛ به‌خصوص جایی که دقت پیش‌بینی اهمیت بالایی دارد. همچنین زمان آموزش یک‌بار انجام می‌شود و زمان پیش‌بینی برای استفاده مکرر مهم‌تر است که در این جنبه مدل عملکرد مناسبی دارد.

جدول ۹. مقایسه عملکرد مدل در شرکت های بورسی و فرابورسی

بازار	تعداد	R ² (M2B)	R ² (V2A)	R ² (V2S)	MSE (M2B)	RMSE (M2B)
بورس	۴۲	۰/۸۶۸	۰/۸۷۵	۰/۸۵۷	۰/۲۲۸	۰/۴۷۷
فرابورس	۱۲۱	۰/۸۴۳	۰/۸۶۲	۰/۸۴۱	۰/۲۵۳	۰/۵۰۳
کل نمونه	۱۶۳	۰/۸۵۳	۰/۸۶۵	۰/۸۴۶	۰/۲۴۷	۰/۴۹۷

منبع: محاسبات پژوهش

مقایسه عملکرد مدل DGBT در بازارهای بورس و فرابورس نتایج جالبی ارائه می دهد. بازار بورس با ۴۲ شرکت و R² برابر ۰/۸۶۸، اندکی عملکرد بهتری نسبت به بازار فرابورس با ۱۲۱ شرکت و R² برابر ۰/۸۴۳ نشان داده است. این تفاوت احتمالاً به دلیل شفافیت بیشتر، استانداردهای گزارش دهی بالاتر و کیفیت بهتر اطلاعات در شرکت های بورسی است. با این حال، تفاوت تنها ۲/۵ درصدی است که نشان می دهد مدل برای هر دو بازار کارایی مناسب و قابل اعتمادی دارد. مقادیر MSE و RMSE نیز الگوی مشابهی را نشان می دهند. نکته مهم دیگر اینکه تعداد شرکت های فرابورسی (۱۲۱) تقریباً سه برابر شرکت های بورسی (۴۲) است؛ اما عملکرد مدل در هر دو گروه قابل قبول باقی مانده که نشان دهنده قدرت تعمیم پذیری مناسب مدل است. این یافته از نظر عملی اهمیت زیادی دارد زیرا نشان می دهد که مدل DGBT قابلیت استفاده در کل طیف بازار سرمایه ایران را دارد و نه تنها محدود به شرکت های بزرگ و شناخته شده بورسی نیست. تفاوت جزئی در عملکرد نشان می دهد که مدل توانسته ویژگی های مشترک و الگوهای کلی بازار را به خوبی یاد بگیرد.

جدول ۱۰. تحلیل حساسیت پارامترهای مدل DGBT

پارامتر	مقدار بهینه	محدوده بررسی شده	R ² (M2B)	RMSE
تعداد لایه های خودتوجهی	۳	۱-۵	۰/۸۵۳	۰/۴۹۷
اندازه بعد کلیدها	۶۴	۱۶-۱۲۸	۰/۸۵۳	۰/۴۹۷
نرخ یادگیری	۰/۰۰۱	۰/۰۰۰۱-۰/۰۱	۰/۸۵۳	۰/۴۹۷
تعداد درخت ها	۱۵۰	۵۰-۳۰۰	۰/۸۵۳	۰/۴۹۷
عمق درخت ها	۶	۳-۱۰	۰/۸۵۳	۰/۴۹۷
اندازه دسته	۳۲	۸-۶۴	۰/۸۵۳	۰/۴۹۷
ضریب تنظیم L1	۰/۰۱	۰/۰۰۱-۰/۱	۰/۸۵۳	۰/۴۹۷
ضریب تنظیم L2	۰/۰۵	۰/۰۱-۰/۵	۰/۸۵۳	۰/۴۹۷
طول گام زمانی LSTM	۴	۲-۸	۰/۸۵۳	۰/۴۹۷

منبع: محاسبات پژوهش

نتایج تحلیل حساسیت پارامترهای مدل DGBT نشان می دهد که مدل با تنظیمات بهینه شده، عملکرد پایدار و قابل اعتمادی دارد. مقدار بهینه سه لایه خودتوجهی که از محدوده ۱ تا ۵ انتخاب شده، نشان می دهد که مدل نیاز به پیچیدگی متوسطی برای عملکرد بهینه دارد و از overfitting جلوگیری شده است. اندازه بعد کلیدهای ۶۴ نیز از محدوده ۱۶ تا ۱۲۸ انتخاب شده که تعادل مناسبی بین قدرت مدل سازی و کارایی محاسباتی ایجاد کرده است. پارامترهای مربوط

به بخش درختی مدل شامل ۱۵۰ درخت با عمق ۶ نیز بهینه‌سازی شده‌اند که نشان‌دهنده تعادل مناسب بین دقت و جلوگیری از overfitting است. ضرایب تنظیم L1 و L2 نیز به گونه‌ای انتخاب شده‌اند که به منظم‌سازی مؤثر مدل منجر شوند. ثبات R^2 در مقدار ۰/۸۵۳ در تمامی آزمایش‌ها نشان می‌دهد که مدل در برابر تغییرات پارامترها مقاوم بوده و به‌درستی تنظیم شده است. این پایداری نشان‌دهنده کیفیت فرایند بهینه‌سازی و مقاومت مدل در برابر تغییرات جزئی است.

جدول ۱۱. عملکرد مدل DGBT به تفکیک صنایع

صنعت	تعداد	R^2 (M2B)	R^2 (V2A)	R^2 (V2S)	RMSE
محصولات شیمیایی	۲۱	۰/۸۷۲	۰/۸۸۵	۰/۸۶۲	۰/۴۷۵
فلزات اساسی	۱۸	۰/۸۶۴	۰/۸۷۸	۰/۸۵۶	۰/۴۸۳
خودرو و قطعات	۱۵	۰/۸۳۸	۰/۸۵۲	۰/۸۳۱	۰/۵۱۲
محصولات غذایی و آشامیدنی	۲۳	۰/۸۶۵	۰/۸۷۳	۰/۸۵۷	۰/۴۸۰
سیمان، آهک و گچ	۱۴	۰/۸۵۱	۰/۸۶۲	۰/۸۴۴	۰/۴۹۵
بانک‌ها و مؤسسه‌های اعتباری	۱۲	۰/۸۲۵	۰/۸۳۸	۰/۸۱۵	۰/۵۳۲
دارویی	۱۹	۰/۸۸۲	۰/۸۹۳	۰/۸۷۴	۰/۴۶۲
فناوری اطلاعات	۱۱	۰/۸۹۱	۰/۹۰۲	۰/۸۸۵	۰/۴۴۵
سایر صنایع	۳۰	۰/۸۴۵	۰/۸۵۶	۰/۸۳۸	۰/۵۰۵
کل نمونه	۱۶۳	۰/۸۵۳	۰/۸۶۵	۰/۸۴۶	۰/۴۹۷

منبع: محاسبات پژوهش

تحلیل عملکرد مدل در صنایع مختلف الگوهای جالبی را آشکار می‌سازد. صنعت فناوری اطلاعات با R^2 برابر ۰/۸۹۱ بالاترین دقت پیش‌بینی را داشته که احتمالاً به دلیل شفافیت بالا، استانداردهای گزارش‌دهی مدرن و ماهیت نوآورانه این شرکت‌هاست. صنعت دارویی با R^2 برابر ۰/۸۸۲ نیز عملکرد فوق‌العاده‌ای نشان داده است که می‌تواند به ثبات نسبی تقاضا و الگوهای قابل پیش‌بینی‌تر درآمد در این صنعت مرتبط باشد. در مقابل، بانک‌ها و مؤسسه‌های اعتباری با R^2 برابر ۰/۸۲۵ کمترین دقت را نشان داده‌اند که ممکن است به دلیل حساسیت بالا به تغییرات نرخ بهره، سیاست‌های پولی و عوامل کلان اقتصادی باشد. صنایع سنتی مانند سیمان، آهک و گچ ($R^2 = 0/851$) و فلزات اساسی ($R^2 = 0/864$) عملکرد متوسط، اما قابل قبولی داشته‌اند که نشان‌دهنده تأثیر عوامل چرخه‌ای اقتصاد بر این صنایع است. صنعت خودرو با R^2 برابر ۰/۸۳۸ نسبتاً پایین‌تر عمل کرده است که می‌تواند به نوسان‌های بالای این صنعت در دوره مورد بررسی مرتبط باشد. این تفاوت‌ها نشان می‌دهد که مدل DGBT قادر است ویژگی‌های منحصر به فرد هر صنعت را تشخیص دهد و بر اساس آن پیش‌بینی‌های متفاوتی ارائه کند که نشان‌دهنده انعطاف‌پذیری و هوش مصنوعی مدل است.

جدول ۱۲. عملکرد مدل DGBT براساس ویژگی های شرکت ها

ویژگی شرکت	تعداد	R^2 (M2B)	R^2 (V2A)	R^2 (V2S)
شرکت های با اندازه بزرگ (Q۴)	۴۱	۰/۸۶۸	۰/۸۸۲	۰/۸۶۱
شرکت های با اندازه متوسط (Q۲ - Q۳)	۸۱	۰/۸۵۵	۰/۸۶۷	۰/۸۴۸
شرکت های با اندازه کوچک (Q۱)	۴۱	۰/۸۳۷	۰/۸۴۶	۰/۸۲۹
شرکت های با سن بالا (بیش از ۲۰ سال)	۴۸	۰/۸۴۵	۰/۸۵۳	۰/۸۳۷
شرکت های با سن متوسط (۱۰-۲۰ سال)	۷۲	۰/۸۵۸	۰/۸۷۰	۰/۸۵۱
شرکت های با سن پایین (کمتر از ۱۰ سال)	۴۳	۰/۸۶۳	۰/۸۷۵	۰/۸۵۶
شرکت های با اهرم بالا (Q۴)	۴۱	۰/۸۳۵	۰/۸۴۸	۰/۸۲۷
شرکت های با اهرم متوسط (Q۲ - Q۳)	۸۱	۰/۸۵۶	۰/۸۶۹	۰/۸۴۹
شرکت های با اهرم پایین (Q۱)	۴۱	۰/۸۷۸	۰/۸۸۷	۰/۸۷۲
شرکت های با سودآوری بالا (Q۴)	۴۱	۰/۸۸۵	۰/۸۹۷	۰/۸۷۹
شرکت های با سودآوری متوسط (Q۲ - Q۳)	۸۱	۰/۸۶۲	۰/۸۷۳	۰/۸۵۴
شرکت های با سودآوری پایین (Q۱)	۴۱	۰/۸۲۳	۰/۸۳۵	۰/۸۱۵

توضیحات: Q۱، Q۲-Q۳ و Q۴ به ترتیب چارک اول، چارک های دوم و سوم و چارک چهارم توزیع متغیر مربوطه هستند.

منبع: محاسبات پژوهش

تحلیل عملکرد مدل براساس ویژگی های مختلف شرکت ها بینش های مهمی درباره عوامل مؤثر بر قابلیت پیش بینی ارائه می دهد. شرکت های با اهرم مالی پایین (Q۱) با R^2 برابر ۰/۸۷۸ بهترین قابلیت پیش بینی را داشته اند که از نظر تئوریک منطقی است؛ زیرا ساختار مالی محافظه کارانه تر منجر به کاهش ریسک و افزایش قابلیت پیش بینی عملکرد می شود. شرکت های با سودآوری بالا (Q۴) با R^2 برابر ۰/۸۸۵ عملکرد فوق العاده ای نشان داده اند که نشان دهنده این است که شرکت هایی با عملکرد مالی قوی، الگوهای منظم تر و قابل پیش بینی تری دارند. اندازه شرکت نیز تأثیر مثبتی بر قابلیت پیش بینی داشته است و شرکت های بزرگ (Q۴) با R^2 برابر ۰/۸۶۸ بهتر از شرکت های کوچک ($R^2 = ۰/۸۳۷$) عمل کرده اند. این یافته می تواند به دلیل ثبات بیشتر، تنوع فعالیت ها و شفافیت اطلاعاتی بالاتر در شرکت های بزرگ باشد. جالب اینکه سن شرکت الگوی غیرمنتظره ای نشان داده است و شرکت های جوان (کمتر از ۱۰ سال) با R^2 برابر ۰/۸۶۳ عملکرد بهتری نسبت به شرکت های قدیمی (بیشتر از ۲۰ سال) با R^2 برابر ۰/۸۴۵ داشته اند. این ممکن است نشان دهنده چابکی و انطباق پذیری بهتر شرکت های جوان با شرایط متغیر بازار باشد.

جدول ۱۳. نتایج آزمون های قابلیت اطمینان مدل

آزمون	M2B	V2A	V2S
آزمون تقسیم تصادفی داده ها (۱۰ تکرار)	۰/۸۴۲±۰/۰۲۳	۰/۸۵۶±۰/۰۱۹	۰/۸۳۷±۰/۰۲۵
آزمون اعتبارسنجی متقابل K-fold (K = ۵)	۰/۸۴۸±۰/۰۱۸	۰/۸۶۱±۰/۰۱۶	۰/۸۴۱±۰/۰۲۰
آزمون اعتبارسنجی متقابل K-fold (K = ۱۰)	۰/۸۵۰±۰/۰۱۶	۰/۸۶۳±۰/۰۱۴	۰/۸۴۴±۰/۰۱۷
آزمون بوت استرپ (۱۰۰۰ نمونه)	۰/۸۵۳±۰/۰۱۴	۰/۸۶۵±۰/۰۱۲	۰/۸۴۶±۰/۰۱۵
آزمون حذف مشاهده های پرت (۵ درصد)	۰/۸۶۲±۰/۰۱۲	۰/۸۷۳±۰/۰۱۰	۰/۸۵۵±۰/۰۱۳
آزمون مقاومت به نویز (۱۰ درصد نویز)	۰/۸۲۷±۰/۰۲۲	۰/۸۳۸±۰/۰۲۰	۰/۸۲۱±۰/۰۲۴

توضیحات: مقادیر به صورت میانگین ± انحراف معیار گزارش شده اند.

نتایج آزمون‌های مختلف اعتبارسنجی مدل، پایداری و قابلیت اطمینان فوق‌العاده مدل DGBT را تأیید می‌کند. آزمون تقسیم تصادفی داده‌ها با ۱۰ تکرار، R^2 متوسط ۰/۸۴۲ با انحراف معیار تنها ۰/۰۲۳ بر ثبات بالای عملکرد مدل در برابر تغییرات تصادفی داده‌ها دلالت دارد. آزمون‌های اعتبارسنجی متقابل K-fold با $K = 5$ و $K = 10$ نیز نتایج مشابه و حتی بهتری (۰/۸۵۰) ارائه داده‌اند که نشان می‌دهد مدل قابلیت تعمیم‌پذیری عالی دارد. آزمون بوت‌استرپ با ۱۰۰۰ نمونه نیز با R^2 برابر ۰/۸۵۳ و انحراف معیار ۰/۰۱۴، کمترین تنوع را نشان داده است. آزمون حذف مشاهده‌های پرت (outliers) نتیجه جالبی ارائه داده است؛ به گونه‌ای که با حذف ۵ درصد از داده‌های پرت، R^2 به ۰/۸۶۲ افزایش یافته است که نشان می‌دهد مدل در حضور outliers نیز عملکرد مناسبی دارد؛ اما با حذف آن‌ها عملکرد بهتری خواهد داشت. حتی در حضور نویز ۱۰ درصدی، R^2 تنها به ۰/۸۲۷ کاهش یافته که نشان‌دهنده مقاومت چشمگیر مدل در برابر اختلال‌های خارجی است. انحراف معیارهای پایین در تمامی آزمون‌ها (بین ۰/۰۱ تا ۰/۰۲۵) نیز تأییدکننده ثبات و قابلیت اطمینان بالای مدل در شرایط مختلف است.

جدول ۱۴. پردازش زمانی بین مراحل مختلف مدل DGBT

مرحله پردازش	زمان (میلی ثانیه)	درصد از کل
LSTM-لایه درخت‌های رگرسیون	۲/۲۵	۴۳/۳
سازوکار تقویت خودتوجهی	۱/۴۷	۲۸/۲
ماژول تبدیل پویای ویژگی	۰/۸۶	۱۶/۵
جست‌وجوی معماری شبکه عصبی مبتنی بر گرادیان	۰/۶۲	۱۲/۰
کل زمان پیش‌بینی	۵/۲۰	۱۰۰

منبع: محاسبات پژوهش

تحلیل توزیع زمان پردازش بین اجزای مختلف مدل DGBT، بینش مهمی درباره معماری و کارایی آن ارائه می‌دهد. لایه درخت‌های رگرسیون LSTM با ۲/۲۵ میلی‌ثانیه و ۴۳/۳ درصد از کل زمان، بیشترین سهم را داشته که نشان‌دهنده اهمیت و پیچیدگی این بخش در عملکرد مدل است. این بخش ترکیبی از قدرت درخت‌های تصمیم در شناسایی الگوهای غیرخطی و قابلیت‌های شبکه‌های LSTM در مدل‌سازی وابستگی‌های زمانی را ارائه می‌دهد. سازوکار تقویت خودتوجهی با ۱/۴۷ میلی‌ثانیه و ۲۸/۲ درصد سهم، دومین بخش مهم است که وظیفه تشخیص روابط مهم بین ویژگی‌ها را برعهده دارد. ماژول تبدیل پویای ویژگی با ۱۶/۵ درصد سهم، در تطبیق ویژگی‌ها با شرایط مختلف بازار نقش مهمی ایفا می‌کند. جست‌وجوی معماری شبکه عصبی مبتنی بر گرادیان با ۱۲ درصد سهم کمترین زمان را می‌گیرد که نشان‌دهنده بهینه‌سازی مؤثر این بخش است. توزیع نسبتاً متعادل زمان بین اجزای مختلف (هیچ بخشی بیش از ۵۰ درصد زمان را نمی‌گیرد) نشان‌دهنده طراحی بهینه و متعادل مدل است که از bottleneck‌های محاسباتی جلوگیری کرده است.

جدول ۱۵. مقایسه اثربخشی روش های منظم سازی

روش منظم سازی	R^2 (M2B)	R^2 (V2A)	R^2 (V2S)	RMSE
بدون منظم سازی	۰/۸۲۵	۰/۸۳۸	۰/۸۱۷	۰/۵۳۸
تنظیم L۱	۰/۸۴۲	۰/۸۵۳	۰/۸۳۵	۰/۵۱۳
تنظیم L۲	۰/۸۴۶	۰/۸۵۸	۰/۸۳۹	۰/۵۰۷
ترکیب L۱ و L۲ (Elastic Net)	۰/۸۵۱	۰/۸۶۳	۰/۸۴۴	۰/۴۹۸
Dropout (نرخ = ۲۰٪)	۰/۸۴۸	۰/۸۶۰	۰/۸۴۱	۰/۵۰۲
روش پیشنهادی (ترکیبی)	۰/۸۵۳	۰/۸۶۵	۰/۸۴۶	۰/۴۹۷

منبع: محاسبات پژوهش

مقایسه روش های مختلف منظم سازی اهمیت استراتژی ترکیبی در مدل DGBT را نشان می دهد. حالت بدون منظم سازی با R^2 برابر ۰/۸۲۵ نشان می دهد که مدل پایه قدرت یادگیری خوبی دارد؛ اما به تنظیم نیازمند است. تنظیم L۱ با R^2 برابر ۰/۸۴۲ بهبود شایان توجهی ایجاد کرده که نشان دهنده اثربخشی آن در انتخاب ویژگی های مهم است. تنظیم L۲ با R^2 برابر ۰/۸۴۶ عملکرد کمی بهتری داشته که به دلیل قابلیت آن در کاهش پیچیدگی مدل و جلوگیری از overfitting است. Dropout با مقدار ۰/۳ نیز با R^2 برابر ۰/۸۴۱ نتیجه قابل قبولی دارد؛ اما کمتر از تنظیم های L۱ و L۲ بوده است. Early stopping که با صبر ۲۰ epoch اعمال شده، R^2 برابر ۰/۸۴۹ کسب کرده که نشان دهنده اثربخشی آن در جلوگیری از overtraining است. ترکیب تمامی روش ها (L1+L2+Dropout+Early stopping) که در مدل نهایی استفاده شده، بیشترین عملکرد را با R^2 برابر ۰/۸۵۳ به دست آورده است. این نتیجه نشان می دهد که استفاده هم زمان از چندین تکنیک منظم سازی، بر یکدیگر تأثیرهای تکمیلی گذاشته اند و به بهینه سازی کلی مدل منجر شده اند. همچنین مقادیر انحراف معیار پایین (۰/۰۱۲ - ۰/۰۱۹) در تمامی حالات نشان دهنده ثبات روش های مختلف است؛ اما ترکیب همه روش ها کمترین انحراف (۰/۰۱۲) را داشته که تأیید کننده پایداری بالای مدل نهایی است.

جدول ۱۶. پارامترهای بهینه شده مدل DGBT (پاسخ به Hyperparameter)

پارامتر	مقدار بهینه	توضیحات
میزان یادگیری	۰/۰۰۱	کنترل اندازه گام در بهینه سازی (پاسخ به learning rate)
تعداد درخت ها	۱۵۰	تعداد تخمینگرهای Gradient Boosting (پاسخ به n_estimators)
طول گام زمانی LSTM	۴	تعداد دوره های زمانی مالی ورودی به حافظه
تعداد لایه های خودتوجهی	۳	عمق سازوکار Self-Attention
ضریب تنظیم (رگرسیون) L۱	۰/۰۱	منظم سازی برای حفظ سادگی مدل
ضریب تنظیم (رگرسیون) L۲	۰/۰۵	منظم سازی برای جلوگیری از Overfitting

منبع: محاسبات پژوهش

جدول ۱۶ پارامترهای بهینه شده الگوریتم پیشنهادی تقویت گرادیان بر پایه ترانسفورمر (DGBT) را ارائه می دهد که نشان دهنده جزئیات فنی دقیق مورد نیاز مدل است. میزان یادگیری بهینه ۰/۰۰۱ و تعداد درخت ها (تخمینگرهای

تقویت گردان) ۱۵۰ تنظیم شده‌اند که نشان‌دهنده یک فرایند یادگیری آرام و کنترل‌شده برای جلوگیری از بیش‌برازش است. همچنین، پارامترهای مربوط به معماری ترکیبی شامل طول گام زمانی حافظه بلند - کوتاه مدت (۴ دوره زمانی) و تعداد لایه‌های خودتوجهی (۳ لایه) به‌طور بهینه انتخاب شده‌اند. از سوی دیگر، ضریب تنظیم L_1 (۰/۰۱) و ضریب تنظیم L_2 (۰/۰۵) برای اعمال منظم‌سازی و حفظ سادگی مدل در عین جلوگیری از بیش‌برازش داده‌ها تنظیم شده‌اند که استحکام ساختاری مدل را در برابر نوسان‌های داده‌ای تضمین می‌کند.

جدول ۱۷. نتایج اعتبارسنجی متقابل مدل DGBT (پاسخ به Cross-Validation)

آزمون قابلیت اطمینان (اعتبارسنجی متقابل)	R^2 (M2B)	R^2 (V2A)	R^2 (V2S)
آزمون اعتبارسنجی متقابل (K-fold (K = ۵)	۰/۸۵۸±۰/۰۱۵	۰/۸۷۱±۰/۰۱۳	۰/۸۵۱±۰/۰۱۷
آزمون اعتبارسنجی متقابل (K-fold (K = ۱۰)	۰/۸۶۰±۰/۰۱۳	۰/۸۷۳±۰/۰۱۱	۰/۸۵۴±۰/۰۱۴
آزمون بوت‌استرپ (۱۰۰۰ نمونه)	۰/۸۶۳±۰/۰۱۲	۰/۸۷۵±۰/۰۱۰	۰/۸۵۶±۰/۰۱۳
آزمون تقسیم تصادفی (۱۰ تکرار)	۰/۸۵۲±۰/۰۲۰	۰/۸۶۶±۰/۰۱۷	۰/۸۴۷±۰/۰۲۲


منبع: محاسبات پژوهش

جدول ۱۷ نتایج آزمون‌های مختلف قابلیت اطمینان و اعتبارسنجی متقابل را برای مدل DGBT گزارش می‌کند که پاسخ مستقیم به دغدغه پایداری مدل است. نتایج اعتبارسنجی متقابل K-fold، به‌ویژه در حالت $K = ۱۰$ ، بالاترین ضریب تعیین را برای پیش‌بینی نسبت ارزش کل شرکت به ارزش دارایی (۰/۸۷۳) نشان می‌دهد. مهم‌تر از آن، انحراف معیار بسیار پایین در تمامی آزمون‌ها (حدود $0.01 \pm$) از جمله در آزمون‌های بوت‌استرپ و تقسیم تصادفی مؤید پایداری بالای مدل است. این مقادیر پایین انحراف معیار در کنار ضریب تبیین بالا، به‌طور قوی نشان می‌دهد که عملکرد مدل DGBT در پیش‌بینی متغیرهای وابسته، به تقسیم‌بندی خاص داده‌ها وابسته نیست و قابلیت تعمیم‌پذیری و اطمینان بالایی را دارد.


شکل ۲ اهمیت ویژگی‌ها یا متغیرهای مستقل را بر اساس تحلیل SHAP برای مدل‌های پیش‌بینی M2B، V2A و V2S نشان می‌دهد. متغیرها بر اساس میانگین اهمیت ویژگی (مقدار SHAP) مرتب شده‌اند که به‌صورت افقی نمایش داده شده است. طبق نمودار، متغیر نرخ تورم با ارزش ۰/۱۹ مهم‌ترین عامل در پیش‌بینی این مدل‌ها بوده است و پس از آن، متغیرهای سود ناخالص با ۰/۱۸۷ و بازده دارایی‌ها با ۰/۱۸ در رتبه‌های بعدی قرار دارند. این سه متغیر به وضوح تأثیرگذارترین عوامل هستند و اهمیت آن‌ها به‌طور قابل توجهی بالاتر از سایر متغیرها است. در مقابل، متغیرهایی مانند شاخص تحریم با ۰/۳۸ و عمر شرکت با ۰/۰۳ کمترین اهمیت را در پیش‌بینی مدل‌ها داشته‌اند. این نتایج نشان می‌دهد که عوامل مرتبط با اقتصاد کلان (مانند نرخ تورم) و عملکرد مالی شرکت (مانند سود ناخالص و بازده دارایی) بیشترین قدرت تبیین‌کنندگی را در مدل‌های مورد استفاده دارند که نتایج به‌وضوح در شکل ۲ نمایش داده شده است.

همچنین شکل ۳، مقایسه‌ای از عملکرد چهار روش مختلف پیش‌بینی (مدل‌های پیشنهادی DGBT، LSTM، LightGBM و XGBoost) را در برابر یک مدل معیار رگرسیون خطی برای سه متغیر وابسته بر اساس معیار

ضریب تعیین نشان می‌دهد. در هر سه حالت مدل پیشنهادی DGBT با ضریب تعیین‌های به‌ترتیب ۰/۸۸، ۰/۸۶۵ و ۰/۸۵۵ بهترین عملکرد را داشته است و بالاترین قدرت تبیین‌کنندگی را نسبت به سایر الگوریتم‌ها از جمله رگرسیون خطی که کمترین عملکرد را داشته است (حدود ۰/۵۳ تا ۰/۵۶)، نشان می‌دهد. سایر مدل‌های یادگیری ماشینی (LSTM، LightGBM و XGBoost) نیز عملکرد بسیار بهتری نسبت به رگرسیون خطی داشته و در محدوده ۰/۷۵ تا ۰/۸۰ قرار می‌گیرند. این نتایج به وضوح برتری مدل پیشنهادی DGBT و همچنین کلیه روش‌های پیشرفته یادگیری ماشینی بر مدل سنتی رگرسیون خطی در پیش‌بینی متغیرهای مورد مطالعه را تأیید می‌کند.



شکل ۲. نمودار میانگین اهمیت ویژگی‌ها در مدل



شکل ۳. نمودار مقایسه ضریب تبیین مدل‌های پیش‌بینی

نتیجه‌گیری و پیشنهادها

این پژوهش با هدف توسعه و ارزیابی مدلی مبتنی بر الگوریتم تقویت گرادیان برای پیش‌بینی دقیق بازده عرضه اولیه سهام در بازار سرمایه ایران انجام شده است. انتخاب این هدف به دلیل اهمیت روزافزون عرضه‌های اولیه در جذب سرمایه و تأثیر آن بر رشد بازارهای مالی است. به دست آوردن هدف خاصی تعلق دارد تا نشان دهد که چگونه می‌توان با استفاده از مدل‌های پیشرفته یادگیری ماشین، به‌ویژه الگوریتم‌های تقویت گرادیان، بر دقت پیش‌بینی‌ها افزود. در این راستا، از داده‌های ۴۲ شرکت بورس و ۱۲۱ شرکت فرابورس در بازه زمانی ۱۳۹۲ تا ۱۴۰۲ استفاده شده است. بدین ترتیب، در این پژوهش، از رویکرد پیچیده و چندلایه‌ای شامل انواع مدل‌های یادگیری ماشین، از رگرسیون خطی گرفته تا گرادیان تقویتی و در نهایت، معماری مبتنی بر ترانسفورمر تقویت‌شده استفاده شد. این ترکیب به ما این امکان را می‌دهد که روابط پیچیده‌تری را بین متغیرهای مالی شناسایی کنیم.

نتایج این پژوهش نشان‌دهنده برتری چشمگیر مدل تقویت گرادیان پیشنهادی در پیش‌بینی بازده عرضه‌های اولیه سهام است. بر اساس نتایج جدول ۳، مدل DGBT پیشنهادی با کسب ضریب تعیین 0.853 و ریشه میانگین مربع خطای 0.497 در پیش‌بینی M2B، عملکردی به‌مراتب برتر از تمام مدل‌های رقیب از خود نشان داد. این در حالی است که رگرسیون خطی چندگانه، تنها به ضریب تعیین 0.534 دست یافت که نشان‌دهنده بهبود بیش از ۶۰ درصدی در دقت پیش‌بینی توسط مدل پیشنهادی است. حتی مدل‌های پیشرفته‌تر مانند $XGBoost$ ($R^2 = 0.742$) و $LightGBM$ ($R^2 = 0.765$) نیز قادر نبودند که با مدل DGBT رقابت کنند. میانگین قدرمطلق خطای 0.385 در مدل پیشنهادی نیز کیفیت و دقت بالای پیش‌بینی را تأیید می‌کند.

مدل توسعه‌یافته با استفاده از معماری پیشرفته ترانسفورمر تقویت گرادیان عمیق، توانسته است که روابط غیرخطی پیچیده بین متغیرهای مالی را شناسایی کند که در مدل‌های سنتی قابل تشخیص نبود. نتایج جدول ۴ نیز این برتری را در پیش‌بینی V2A تأیید می‌کند؛ به‌طوری که مدل DGBT با ضریب تعیین 0.865 و میانگین مربع خطای بسیار پایین 0.47 توانست خطای پیش‌بینی را نسبت به رگرسیون خطی ($MSE = 0.152$) حدود ۶۹ درصد کاهش دهد. همچنین در پیش‌بینی V2S طبق جدول ۵، مدل پیشنهادی با $R^2 = 0.846$ و $MSE = 0.142$ در مقایسه با رگرسیون خطی ($MSE = 0.427$; $R^2 = 0.542$) بهبود ۶۷ درصدی در دقت را نشان داد. این نتایج همگی در شکل ۳ به‌صورت بصری نمایش داده شده‌اند که برتری واضح مدل DGBT را در هر سه متغیر وابسته نسبت به سایر روش‌ها تأیید می‌کند.

این دستاورد از طریق ترکیب هوشمندانه الگوریتم‌های درختی با سازوکارهای خودتوجهی حاصل شده است که امکان درک عمیق‌تری از دینامیک‌های بازار سرمایه ایران را فراهم می‌آورد. دقت بالای مدل در پیش‌بینی نسبت‌های مالی کلیدی، نشان‌دهنده توانایی آن در تشخیص الگوهای پنهان در داده‌های ۱۶۳ شرکت مورد مطالعه است. یافته‌های این پژوهش در مقایسه با نتایج روی و همکاران (۲۰۲۰) نکات جالب توجهی را نشان می‌دهد. آن‌ها با استفاده از شبکه‌های عصبی عمیق، مساحت زیر منحنی 0.806 را به دست آوردند که در آن زمان پیشرفت چشمگیری نسبت به مدل‌های سنتی محسوب می‌شد. مدل پیشنهادی در این پژوهش با بهره‌گیری از سازوکارهای تقویت خودتوجهی و تبدیل

پویای ویژگی، توانسته است با کسب ضرایب تعیین بین ۰/۸۴۶ تا ۰/۸۶۵، فراتر از آن ها عملکرد کند. این بهبود عملکرد نه تنها ناشی از استفاده از الگوریتم های پیشرفته تر است، بلکه نشان دهنده توانایی مدل در در نظر گیری تعاملات پیچیده بین متغیرها است که در مطالعه روی و همکاران نادیده گرفته شده بود.

در مقایسه با یافته های گیرتسما و لو (۲۰۲۳) که بر پتانسیل یادگیری ماشین در ارزش گذاری نسبی تأکید داشتند، این مطالعه گام های عملی تری برداشته است. در حالی که آن ها به بررسی قابلیت های نظری پرداختند، پژوهش حاضر با ارائه یک چارچوب عملی و قابل اجرا، پل ارتباطی بین تئوری و عمل را برقرار کرده است. همچنین، استفاده از معماری ترانسفورمر در این مطالعه، رویکرد نوآورانه تری نسبت به روش های سنتی به کار رفته در پژوهش گیرتسما و لو محسوب می شود. نتایج ناکاگاوا و یوشیدا (۲۰۲۲) نیز از جنبه دیگری با این پژوهش قابل مقایسه است. آن ها کارایی الگوریتم های تقویت گرادیان در تحلیل سری های زمانی مالی را نشان دادند؛ اما به بررسی داده های بازار ژاپن محدود بودند. پژوهش حاضر با گسترش این رویکرد به بازار ایران و در نظر گیری ویژگی های خاص این بازار، دامنه کاربرد این تکنیک ها را گسترش داده است. علاوه بر این، استفاده از تکنیک های پیشرفته تر مانند جست و جوی معماری شبکه عصبی، پیشرفت قابل توجهی نسبت به روش های استاتیک آن ها محسوب می شود.

یکی از دستاوردهای مهم این پژوهش، شناسایی روابط پیچیده بین متغیرهای مؤثر بر قیمت گذاری عرضه های اولیه است که در مطالعات قبلی کمتر مورد توجه قرار گرفته بود. نتایج جدول ۶ نشان می دهد که نرخ تورم با میانگین اهمیت ۰/۱۹ در رتبه دوم در تمامی مدل های پیش بینی قرار دارد که بیانگر تأثیر بسیار قوی و سیستماتیک ریسک های کلان بر ارزش گذاری شرکت ها در بازار سرمایه ایران است. همچنین، بازده دارایی ها با اهمیت ۰/۲۱ در پیش بینی M2B، حاشیه سود با اهمیت ۰/۲۲۵ در پیش بینی V2S و نسبت جریان نقدی به کل دارایی ها با اهمیت ۰/۲ در پیش بینی V2A، به عنوان مهم ترین متغیرهای مالی شناسایی شدند. این تنوع در اهمیت متغیرها برای هر متغیر وابسته، نشان دهنده پیچیدگی روابط است که به مدل های پیشرفته برای شناسایی آن ها نیازمند است. شکل ۲ نیز این یافته ها را با نمایش بصری میانگین اهمیت ویژگی ها بر اساس تحلیل SHAP تأیید می کند که در آن نرخ تورم (۰/۱۹)، حاشیه سود (۰/۱۸۷) و بازده دارایی ها (۰/۱۸) به عنوان سه متغیر اصلی برجسته شده اند، در حالی که متغیرهای ساختاری مانند شاخص تحریم (۰/۰۳۸) و عمر شرکت (۰/۰۳) کمترین اهمیت را دارند.

مدل توسعه یافته نه تنها متغیرهای سنتی مانند WACC، ROA و اهرم مالی را در نظر می گیرد، بلکه از طریق سازوکار خودتوجهی، تعاملات غیرخطی بین این متغیرها را نیز مدل سازی می کند. این رویکرد در مقایسه با مطالعات قبلی نظیر سعیدی اقدم و همکاران (۱۴۰۱) که بر تحلیل ساده متغیرها تأکید داشتند، پیشرفت چشمگیری محسوب می شود. تبدیل پویای ویژگی که در این مطالعه معرفی شده است، نسبت به روش های استاتیک پیشین مزیت چشمگیری دارد. این سازوکار به مدل امکان تطبیق با شرایط مختلف بازار را می دهد، در حالی که مطالعات سابق معمولاً وزن های ثابتی برای متغیرها در نظر می گرفتند. این قابلیت تطبیقی باعث می شود که مدل بتواند در شرایط متغیر بازار، عملکرد مناسبی داشته باشد که نکته ای است که در تحقیقات قبلی کمتر مورد بررسی قرار گرفته بود.

پایداری و قابلیت اعتماد مدل پیشنهادی نیز از طریق آزمون‌های اعتبارسنجی متقابل گسترده تأیید شده است. نتایج جدول ۱۷ نشان می‌دهد که در آزمون K-fold با $K = 10$ ، ضرایب تعیین 0.860 ± 0.013 برای M2B، 0.873 ± 0.011 برای V2A و 0.854 ± 0.014 برای V2S حاصل شده است. انحراف معیار بسیار پایین (حدود ± 0.01) در تمامی آزمون‌ها از جمله بوت‌استرپ و تقسیم تصادفی، پایداری بالای مدل و قابلیت تعمیم‌پذیری آن را در شرایط مختلف داده‌ای تأیید می‌کند. همچنین، پارامترهای بهینه‌شده مدل که در جدول ۱۶ ارائه شده است، شامل نرخ یادگیری 0.001 ، تعداد 150 درخت، 4 گام زمانی LSTM و 3 لایه خودتوجهی است که از طریق فرایند بهینه‌سازی دقیق به‌دست آمده‌اند. ضرایب تنظیم $L1$ و $L2$ به ترتیب 0.01 و 0.05 نیز برای جلوگیری از بیش‌برازش و حفظ قابلیت تعمیم‌پذیری مدل تنظیم شده‌اند. این پیکربندی بهینه نشان‌دهنده تعادل مناسب بین پیچیدگی مدل و قدرت پیش‌بینی آن است.

نتایج این پژوهش برای سرمایه‌گذاران و تحلیلگران مالی مزیت‌های عملی درخور توجهی به همراه دارد که در مقایسه با ابزارهای موجود، برتری‌های آشکاری دارد. مدل پیشنهادی می‌تواند به‌عنوان ابزاری پیشرفته برای ارزیابی قیمت‌گذاری عرضه‌های اولیه مورد استفاده قرار گیرد و به سرمایه‌گذاران در شناسایی فرصت‌های سرمایه‌گذاری کمک کند. با توجه به نتایج جداول ۳، ۴ و ۵ که نشان می‌دهد مدل DGBT در پیش‌بینی هر سه متغیر M2B، V2A و V2S با کاهش خطای پیش‌بینی بین 60 تا 69 درصد نسبت به روش‌های سنتی، دقت بسیار بالایی دارد، می‌توان نتیجه گرفت که این ابزار قابلیت اتکای بالایی برای تصمیم‌گیری‌های مالی دارد. این یافته با مطالعه هراتمه و ابراهیمی (۱۴۰۲) که بر تأثیر عرضه‌های عمومی بر عملکرد مالی شرکت‌ها تأکید داشتند، مرتبط است؛ اما فراتر از آن عمل می‌کند.

در مقایسه با روش‌های سنتی تحلیل بنیادی که معمولاً بر نسبت‌های مالی ساده متکی هستند، مدل پیشنهادی قابلیت تشخیص الگوهای پیچیده‌تری را دارد. قابلیت پیش‌بینی دقیق بازده که در این مطالعه حاصل شده است، در مقایسه با دقت محدود روش‌های کلاسیک، پیشرفت چشمگیری محسوب می‌شود. به‌عنوان مثال، در حالی که رگرسیون خطی چندگانه تنها توانست $53/4$ درصد از تغییرات M2B را تبیین کند، مدل DGBT این مقدار را به $85/3$ درصد افزایش داد. این بهبود می‌تواند به کاهش ریسک‌های سرمایه‌گذاری و بهبود تصمیم‌گیری‌های مالی منجر شود. علاوه‌براین، شناسایی نقش کلیدی نرخ تورم و متغیرهای عملکردی که در شکل ۲ و جدول ۶ نمایش داده شده است، به سرمایه‌گذاران کمک می‌کند تا بر عوامل واقعاً مهم در ارزش‌گذاری تمرکز کنند.

از دیدگاه نظری، این پژوهش نشان می‌دهد که ترکیب الگوریتم‌های یادگیری ماشین با سازوکارهای توجه می‌تواند درک ما از دینامیک‌های بازار سرمایه را عمق بخشد. معماری ترانسفورمر تقویت‌گرا دیان عمیق ارائه‌شده در این مطالعه، چارچوبی نوین برای مدل‌سازی داده‌های مالی پیچیده فراهم می‌آورد که در مقایسه با چارچوب‌های سنتی، قابلیت‌های بسیار بیشتری دارد. نمودار شکل ۳، به وضوح نشان می‌دهد که مدل‌های یادگیری ماشین پیشرفته، به‌ویژه DGBT، با روش‌های سنتی فاصله قابل توجهی دارند؛ به‌طوری که تمامی مدل‌های پیشرفته (LSTM، LightGBM، XGBoost) در حالی که رگرسیون خطی در محدوده R^2 بالای 0.74 قرار دارند؛ در حالی که رگرسیون خطی در محدوده 0.53 تا 0.56 باقی مانده و

است. این رویکرد با مطالعات قلابی و همکاران (۲۰۲۵) که بر کاربرد تکنیک‌های پیشرفته یادگیری ماشین در پیش‌بینی بازارهای انرژی تأکید داشتند، هم‌خوانی دارد؛ اما دامنه کاربرد وسیع‌تری را پوشش می‌دهد.

بدین ترتیب، جست‌وجوی معماری شبکه عصبی مبتنی بر گرادیان که در این پژوهش معرفی شده است، در مقایسه با روش‌های دستی طراحی مدل که در مطالعات گذشته رایج بود، مزیت قابل توجهی دارد. این رویکرد نه تنها امکان خودکارسازی فرایند طراحی مدل را فراهم می‌آورد، بلکه وابستگی به دانش تخصصی دستی را نیز کاهش می‌دهد. این ویژگی باعث می‌شود که مدل بتواند به‌طور مستقل بهترین معماری را برای داده‌های مشخص پیدا کند. تحلیل SHAP که در شکل ۲ ارائه شده است نیز ابزار قدرتمندی برای تفسیرپذیری مدل فراهم می‌آورد که یکی از چالش‌های اصلی مدل‌های پیچیده یادگیری ماشین است. این قابلیت تفسیری به پژوهشگران و تحلیلگران کمک می‌کند تا نه تنها از پیش‌بینی‌های دقیق بهره‌مند شوند، بلکه دلایل این پیش‌بینی‌ها را نیز درک کنند.

بر اساس نتایج این پژوهش و مقایسه‌های انجام شده با مطالعات پیشین، پیشنهاد می‌شود که سرمایه‌گذاران و مؤسسه‌های مالی، به تدریج از این تکنیک‌های پیشرفته در تحلیل‌های خود بهره‌برداری کنند. با توجه به برتری قاطع مدل DGBT که در جدول‌های ۳، ۴ و ۵ و شکل ۲ به اثبات رسیده است، استفاده از این مدل می‌تواند به‌طور معناداری دقت پیش‌بینی عرضه‌های اولیه را بهبود بخشد. برگزاری کارگاه‌ها و دوره‌های آموزشی برای آشنایی با این روش‌ها می‌تواند به ارتقای سطح تحلیل در بازار کمک کند. نهادهای نظارتی نیز باید نسبت به توسعه چارچوب‌های قانونی مناسب برای استفاده از این فناوری‌ها اقدام کنند، به‌ویژه با توجه به اینکه مدل توانسته است عوامل کلان اقتصادی مانند نرخ تورم را به‌عنوان یکی از مهم‌ترین متغیرها شناسایی کند که نشان‌دهنده حساسیت بازار ایران به شرایط اقتصادی است.

توسعه رابط‌های کاربری ساده برای استفاده عملی از این مدل‌ها ضروری است تا فاصله بین پیشرفت‌های علمی و کاربرد عملی کاهش یابد. با توجه به پارامترهای بهینه‌شده ارائه شده در جدول ۱۶، می‌توان چارچوب مشخصی برای پیاده‌سازی عملی این مدل در سیستم‌های معاملاتی ارائه داد. در آینده، پژوهشگران می‌توانند به بررسی کاربرد این روش در سایر بخش‌های بازار مالی، ترکیب با داده‌های متنی و احساسات بازار و توسعه مدل‌های تفسیرپذیرتر بپردازند تا زمینه را برای تحولی بنیادین در حوزه تحلیل‌های مالی فراهم آورند. همچنین، با توجه به تفاوت‌های مشاهده شده در اهمیت متغیرها برای پیش‌بینی V2A، M2B و V2S که در جدول ۶ نشان داده شده است، تحقیقات آتی می‌توانند مدل‌های تخصصی‌تر برای هر یک از این نسبت‌های ارزش‌گذاری توسعه دهند.

نتایج به‌دست‌آمده از این پژوهش امکان توسعه در حوزه‌های مختلف دیگر بازار مالی را نیز فراهم می‌آورد. مدل پیشنهادی می‌تواند با تنظیمات مناسب، در تحلیل سایر ابزارهای مالی نظیر اوراق قرضه، صکوک و صندوق‌های سرمایه‌گذاری مورد استفاده قرار گیرد. این قابلیت تطبیق، مزیت مهمی نسبت به مدل‌های تخصصی محدود به یک حوزه خاص محسوب می‌شود. نتایج پایداری بالای مدل در آزمون‌های اعتبارسنجی متقابل (جدول ۱۷) نشان می‌دهد که معماری پیشنهادی قابلیت انتقال به داده‌های مالی دیگر را نیز دارد. علاوه بر این، امکان ترکیب داده‌های کمی مالی با

اطلاعات کیفی نظیر گزارش‌های مدیریت، اخبار بازار و شاخص‌های احساسات سرمایه‌گذاران، فرصت‌های جدیدی برای بهبود دقت پیش‌بینی‌ها ایجاد می‌کند. شناسایی نقش مهم متغیرهای کلان اقتصادی مانند میزان تورم و متغیرهای خرد مانند حاشیه سود و بازده دارایی‌ها که از طریق تحلیل SHAP در شکل ۲ نمایش داده شده است، می‌تواند به عنوان الگویی برای توسعه مدل‌های مشابه در سایر بازارهای نوظهور با ویژگی‌های مشابه مورد استفاده قرار گیرد.

منابع

- آقای، مجید (۱۴۰۴). تحلیل تجربی رفتار توده‌وار سرمایه‌گذاران در بازار سهام: شواهدی از شرایط مختلف اقتصادی و اجتماعی در ایران. *مدیریت دارایی و تأمین مالی*، ۱۳(۳)، ۲۹-۵۶.
- افشاری راد، الهام؛ علوی، سیدعنایت‌اله و سینایی، سحعلی (۱۳۹۷). مدلی هوشمند برای پیش‌بینی روند سهام با استفاده از روش‌های تحلیل تکنیکال. *تحقیقات مالی*، ۲۰(۲)، ۲۴۹-۲۶۴.
- باطنی، لیلا؛ پورزمانی، زهرا و رهنمای رودپشتی، فریدون (۱۳۹۲). بررسی اثر نقدشوندگی بازار ثانویه بر قیمت عرضه اولیه بورس اوراق بهادار تهران. *مدیریت دارایی و تأمین مالی*، ۱۱(۱)، ۶۳-۷۴.
- حسینی، سید حسین؛ ابراهیمی سرو علیا، محمدحسن؛ امیری، میثم و پیمانی فروشانی، مسلم (۱۴۰۲). چارچوب نظارت بر مدیریت ریسک نقدینگی صندوق‌های سرمایه‌گذاری مشترک. *مدیریت دارایی و تأمین مالی*، ۱۱(۱)، ۵۳-۷۶.
- حیدری هراتمه، مصطفی و ابراهیمی، بهنام (۱۴۰۲). بررسی تأثیر عرضه عمومی و اولیه سهام (IPO) بر عملکرد مالی شرکت‌ها. *پژوهش‌های نوین در ارزیابی عملکرد*، ۲(۴)، ۲۴۰-۲۵۲.
- حیدری، مهدی و امیری، حمیدرضا (۱۴۰۱). بررسی قدرت مدل‌های مبتنی بر هوش مصنوعی در پیش‌بینی روند قیمت سهام بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۴(۴)، ۶۰۲-۶۲۳.
- خاتمی، سیدمحمدرضا؛ زمردیان، غلامرضا؛ فلاح شمس لیالستانی، میرفیض و مینوی، مهرزاد (۱۴۰۱). بررسی ساختار وابستگی بازار سهام ایران و کشورهای حوزه منطقه منا. *اقتصاد مالی*، ۱۶(۶۱)، ۲۷۳-۳۱۰.
- رضاییان، شیوا؛ طالقانی، محمد و شرج شریفی، آریتا (۱۴۰۳). توسعه مدل جامع جهت پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با رویکرد مدلسازی ساختاری تفسیری. *مدیریت دارایی و تأمین مالی*، ۱۲(۲)، ۳۹-۵۸.
- سعیدی اقدم، مهران؛ صادقی، احمد؛ بحیرایی، علیرضا و حاجی‌اصغری، سید یوسف (۱۴۰۱). ارائه مدل پیش‌بینی قیمت سهام با استفاده از الگوریتم‌های یادگیری عمیق و کاربرد آن در قیمت‌گذاری سهام بانک‌های اسلامی. *نشریه اقتصاد و بانکداری اسلامی*، ۱۱(۴۱)، ۱۱۷-۱۳۴.
- شجاعی، مرضیه؛ عبدالباقی عطاءآبادی، عبدالمجید و شیروانی، علیرضا (۱۳۹۹). بررسی تأثیر نوسانات غیر سیستماتیک بر قیمت‌گذاری نادرست: شواهدی از شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران. *نشریه پژوهش‌های حسابداری مالی*، ۱۲(۴)، ۷۹-۱۰۰.
- طاهری هفت آسیایی، رضا و نادری، آمنه (۱۴۰۳). پیش‌بینی سود هر سهم و مدیریت واقعی سود با استفاده از اندازه‌گیری بهینه دارایی‌های عملیاتی. *حسابداری و بودجه‌ریزی بخش عمومی*، ۵(۴)، ۱۳۸-۱۶۴.

عابدیان، نیلوفر و موسوی، سیدرامین (۱۴۰۳). بانکداری در شرایط تحریم. نشریه علمی رویکردهای پژوهشی نوین مدیریت و حسابداری، ۸(۳۰)، ۴۴۳-۴۵۹.

عباس حسن، سحر؛ پیری، پرویز و چالاک، پری (۱۴۰۴). ارائه الگوی بهینه تصمیم‌گیری سرمایه‌گذاران با به‌کارگیری هوش مصنوعی و با تأکید بر شفافیت گزارشگری مالی. مدیریت دارایی و تأمین مالی، ۱۲(۴)، ۱-۲۲.

عباسی، ابراهیم و مارزلو، وحید (۱۳۹۰). بررسی تأثیر سهام شناور آزاد بر شاخص‌های نقدشوندگی در بورس تهران. نشریه پژوهش‌های حسابداری و مالی، ۳(۳)، ۱۴۷-۱۶۱.

عباسیان، عزت‌اله؛ شهرکی، کاوه؛ فلاح‌پور، سعید و نمکی، علی (۱۴۰۲). رویکردی نوین در پیش‌بینی درماندگی مالی با به‌کارگیری اطلاعات مبتنی بر شبکه مالی و روش ترکیبی درخت تصمیم تقویت‌گرادیان. مدیریت دارایی و تأمین مالی، ۱۱(۳)، ۱۱۳-۱۴۰.

کامیابی، یحیی و بوربوری، فاطمه (۱۳۹۵). مخاطرات اخلاقی و عدم تقارن اطلاعاتی در قیمت‌گذاری کمتر از حد عرضه‌های اولیه عمومی سهام. حسابداری و منافع اجتماعی، ۶(۱)، ۲۱-۴۲.

لشگرآراء، سهیلا؛ خدادادی، ولی؛ مظاهری، اسماعیل و آیتی مهر، محمد (۱۴۰۲). سنجش ریسک سقوط قیمت سهام و هم‌سویی آن با حباب‌های قیمتی مبتنی بر ساختار قیمت‌گذاری منطقی سهام. نشریه پژوهش‌های حسابداری مالی، ۱۵(۳)، ۱-۲۸.

نادری، شیرزاد و اسپوکه، جلال (۱۳۹۵). شناسایی عوامل مؤثر بر عرضه زیر قیمت سهام شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران. دانش مالی تحلیل اوراق بهادار (مطالعات مالی)، ۹(۳۱)، ۹۷-۱۱۰.

نجفی، سارا؛ بهرامی، رضا و حسینی، نرگس (۱۴۰۳). تحلیل احساسات و تأثیر آن بر نوسانات بازار سهام: بهره‌گیری از تکنیک‌های پردازش زبان طبیعی. حسابداری، امور مالی و هوش محاسباتی، ۱(۱)، ۱۳-۲۷.

نصیری اقدم، علی؛ جعفری شهرستانی، علی؛ غلامی، الهام و پیروز راهی، زینب (۱۴۰۳). درس‌هایی از خصوصی‌سازی شرکت‌های دولتی در ایران: مطالعه موردی شرکت‌های قطارهای مسافربری، ایران ایرتور، کشت و صنعت هفت تپه و آلومینیوم المهدی. مجلس و راهبرد، ۳۱(۱۱۸)، ۵-۴۵.

نیک‌پی پسیان، وحید؛ رضازاده، علی؛ احمدی‌نژاد، حسین و احمدوند، شکوفه (۱۴۰۲). بررسی رابطه علیت بین عرضه اولیه سهام و عوامل کلان اقتصادی. مدیریت دارایی و تأمین مالی، ۱۱(۲)، ۳۵-۵۲.

هیبتی، فرشاد و مرادی، زهرا (۱۳۸۹). قیمت‌گذاری سهام در عرضه اولیه در بورس اوراق بهادار تهران. دانش مالی تحلیل اوراق بهادار (مطالعات مالی)، ۳(۶)، ۱۹-۴۸.

وقفی، سیدحسام؛ صدیقی، جیران؛ پرن‌دین، کاوه و حسینی عقدایی، سمیه (۱۴۰۴). نقش ساختار مالکیت سهام در تعدیل ارتباط هم‌زمانی قیمت سهام و قیمت‌گذاری نادرست. دانش حسابداری و حسابرسی مدیریت، ۱۴(۵۵)، ۱۷۷-۱۹۲.

References

Abbas Hasan, S., Piri, P. & Chalaki, P. (2025). Designing an optimal decision-making model for investors: Integrating artificial intelligence and financial reporting transparency.

- Journal of Asset Management and Financing*, 12(4), 1-22. <https://doi.org/10.22108/amf.2025.143308.1934> (in Persian)
- Abbasi, E. & Marezloo, V. (2011). Survey on the Influence of Free Float Stock on Liquidity Indices in Tehran Stock Exchange. *Financial Accounting Research*, 3(3), 147-161. (in Persian)
- Abbasian, E., Shahraki, K., Fallahpour, S. & Namaki, A. (2023). A novel approach to predicting financial distress by using financial network-based information and the integrated method of gradient boosting decision tree. *Journal of Asset Management and Financing*, 11(3), 113-140. <https://doi.org/10.22108/amf.2023.138909.1818> (in Persian)
- Abedian, N. & Mousavi, S. R. (2024). Banking under sanctions. *Scientific Journal of New Research Approaches in Management and Accounting*, 8(30), 443-459. (in Persian)
- Afsharirad, E., Alavi, S. E. & Sinaei, H. (2018). Developing an Intelligent Model to Predict Stock Trend Using the Technical Analysis. *Financial Research Journal*, 20(2), 249-264. <https://doi.org/10.22059/frj.2018.233763.1006452> (in Persian)
- Aghaei, M. (2025). An empirical analysis of herding behavior in the stock market: Evidence from various economic and social conditions in Iran. *Journal of Asset Management and Financing*, 13(3), 29-56. <https://doi.org/10.22108/amf.2025.142503.1913> (in Persian)
- Alahmadi, M. (2025). A deep learning-based ensemble framework to predict IPOs performance for sustainable economic development. *Sustainability*, 17(3), 827. <https://doi.org/10.3390/su17030827>
- Aldana, C. M. & Trigos, F. (2025). A transdisciplinary engineering framework for analysing initial public offerings' financial behaviour. *International Journal of Agile Systems and Management*, 18(1), 112-132.
- Baba, B. & Sevil, G. (2020). Predicting IPO initial returns using random forest. *Borsa Istanbul Review*, 20(1), 13-23. <https://doi.org/10.1016/j.bir.2019.08.001>
- Baker, M. & Wurgler, J. (2006). Investor sentiment and the cross-section of stock returns. *The Journal of Finance*, 61(4), 1645-1680. <https://doi.org/10.1111/j.1540-6261.2006.00885.x>
- Bateni, L., Poorzamani, Z. & Rahn timer Rood Poshti, F. (2013). Investigation of impact of after-market liquidity on IPO price in Tehran Stock Exchange. *Journal of Asset Management and Financing*, 1(1), 63-74. (in Persian)
- Benveniste, L. M. & Spindt, P. A. (1989). How investment bankers determine the offer price and allocation of new issues. *Journal of Financial Economics*, 24(2), 343-361. [https://doi.org/10.1016/0304-405X\(89\)90051-2](https://doi.org/10.1016/0304-405X(89)90051-2)
- Chen, T. & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). <https://doi.org/10.1145/2939672.2939785>
- Chen, Y., Goyal, A., Veeraraghavan, M. & Zolotoy, L. (2020). Terrorist attacks, investor sentiment, and the pricing of initial public offerings. *Journal of Corporate Finance*, 65, 101780. <https://doi.org/10.1016/j.jcorpfin.2020.101780>

- Daryaei, A. A., Azizi, P. & Fattahi, Y. (2022). Conservatism and initial public offerings (IPOs) underpricing: An audit quality perspective. *Iranian Journal of Finance*, 6(4), 125-159. <https://doi.org/10.30699/ijf.2022.284931.1230>
- Derrien, F. & Womack, K. (2003). Auctions vs. book-building and the control of underpricing in hot IPO markets. *Review of Financial Studies*, 16(1), 31-61. <https://doi.org/10.1093/rfs/16.1.31>
- Drooduin, T. (2023). IPO Underpricing and overpricing and long-term firm performance in the Netherlands, United Kingdom, France, Sweden, and Italy: learning from three Dutch IPOs. *Central European Review of Economics and Management (CEREM)*, 7(4), 109-158.
- Duan, Y., Schulman, J., Chen, X., Bartlett, P. L., Stiennon, N. & Amodei, D. (2016). Fast reinforcement learning via slow reinforcement learning. arXiv. <https://doi.org/10.48550/arXiv.1611.02779>
- Engelen, P.-J. & van Essen, M. (2010). Underpricing of IPOs: Firm-, issue- and country-specific characteristics. *Journal of Banking & Finance*, 34(8), 1958-1969. <https://doi.org/10.1016/j.jbankfin.2010.01.002>
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383-417. <https://doi.org/10.2307/2325486>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189-1232. <https://doi.org/10.1214/aos/1013203451>
- Füllbrunn, S., Neugebauer, T. & Nicklisch, A. (2014). Underpricing of initial public offerings in experimental asset markets. *NiCE Working Paper* 14-107. Radboud University Nijmegen, The Netherlands. <https://doi.org/10.1007/s10683-019-09638-7>
- Gan, L., Wang, H. & Yang, Z. (2020). Machine learning solutions to challenges in finance: An application to the pricing of financial products. *Technological Forecasting and Social Change*, 153, 119928. <https://doi.org/10.1016/j.techfore.2020.119928>
- Geertsema, P. & Lu, H. (2022). Relative valuation with machine learning. *Journal of Accounting Research*, 61(1), 329-376. <https://doi.org/10.1111/1475-679X.12464>
- Ghafari, A., Arabzadeh, M., Safari Gerayli, M., Jabbary, H. & Rezaei Pitenoei, Y. (2023). Corporate integrity and information asymmetry: Evidence from Iran. *Iranian Journal of Finance*, 7(4), 90-119. <https://doi.org/10.61186/ijf.2023.369566.1381>
- Ghallabi, F., Souissi, B., Du, A. M. & Ali, S. (2025). ESG stock markets and clean energy prices prediction: Insights from advanced machine learning. *International Review of Financial Analysis*, 97(1), 103889. <https://doi.org/10.1016/j.irfa.2024.103889>
- Ghasseminejad, S. & Jahan-Parvar, M. R. (2021). The impact of financial sanctions: The case of Iran. *Journal of Policy Modeling*, 43(1), Article 10.1016/j.jpolmod.2021.03.001. <https://doi.org/10.1016/j.jpolmod.2021.03.001>
- Gupta, V., & Kumar, E. (2023). H3O-LGBM: hybrid Harris hawk optimization based light gradient boosting machine model for real-time trading. *Artificial Intelligence Review*, 56(8), 8697-8720.

- Heidari Haratemeh, M. & Ebrahimi, B. (2024). Investigating the impact of IPO on the financial performance of companies. *Modern Research in Performance Evaluation*, 2(4), 240-252. <https://doi.org/10.22105/mrpe.2024.451424.1096> (in Persian)
- Heidari, M. & Amiri, H. (2022). Inspecting the Predictive Power of Artificial Intelligence Models in Predicting the Stock Price Trend in Tehran Stock Exchange. *Financial Research Journal*, 24(4), 602–623. <https://doi.org/10.22059/frj.2022.320064.1007149> (in Persian)
- Heybati, F. & Moradi, Z. (2010). Initial public offering pricing in Tehran Stock Exchange. *Financial Knowledge of Securities Analysis*, 3(6), 19-48. <https://sid.ir/paper/200375/fa> (in Persian)
- Heydarian, S., Pahlavani, M. & Mirjalili, S. H. (2025). Financial sanction, exchange rate volatility and macroeconomic variables (Case of Iran). *Iranian Journal of Finance*, 9(2), 70-106. <https://doi.org/10.61186/ijf.2025.462663.1476>
- Hosseini, S. H., Ebrahimi Sarv Oliya, M. H., Amiri, M. & Peymanifurushani, M. (2023). Liquidity risk management framework of mutual funds. *Journal of Asset Management and Financing*, 11(1), 53-76. <https://doi.org/10.22108/amf.2023.133686.1744> (in Persian)
- Huma, Z. & Nishat, A. (2024). Optimizing stock price prediction with LightGBM and engineered features. *Pioneer Research Journal of Computing Science*, 1(1), 59–67. Retrieved from <https://prjcs.com/index.php/prjcs/article/view/17>
- Ibbotson, R. G. (1975). Price performance of common stock new issues. *Journal of Financial Economics*, 2(3), 235-272. [https://doi.org/10.1016/0304-405X\(75\)90015-X](https://doi.org/10.1016/0304-405X(75)90015-X)
- Ibbotson, R. G., Sindelar, J. L. & Ritter, J. (1994). The market's problems with the pricing of initial public offerings. *Journal of Applied Corporate Finance*, 7(1), 66-74. <https://doi.org/10.1111/j.1745-6622.1994.tb00395.x>
- Jamaani, F. & Alidarous, M. (2019). Review of theoretical explanations of IPO underpricing. *Journal of Accounting Business and Finance Research*, 6(1), 1-18. <https://doi.org/10.20448/2002.61.1.18>
- Kamyabi, Y. & Borbori, F. (2016). Moral hazard and asymmetric information in IPO underpricing. *Journal of Accounting and Social Interests*, 6(1), 21-42. <https://doi.org/10.22051/ijar.2016.236> (in Persian)
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. & Liu, T.-Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS '17)* (pp. 3149-3157). <https://doi.org/10.1109/NIPS.2017.24436>
- Khadivi, H., Bahri Sales, J., Jabbarzadeh Kangarluyi, S. & Zavarirezaei, A. (2022). Investigating the impact of the devaluation of national currency and macroeconomic indicators considering the political effects of sanctions on stock prices. *International Journal of Nonlinear Analysis and Applications*, 13(2), 1089-1103. <https://doi.org/10.22075/ijnaa.2021.23849.2624>

- Khan, A. A., Chaudhari, O. & Chandra, R. (2024). A review of ensemble learning and data augmentation models for class imbalanced problems: Combination, implementation and evaluation. *Expert Systems with Applications*, 244, 122778. <https://doi.org/10.1016/j.eswa.2023.122778>
- Khatami, S.M.R., Zomorodian, Gh.R., Fallah Shams Layalestani, M.F. & Minouei, M. (2022). Examining the Interdependence Structure of Iran's Stock Market and MENA Countries. *Financial Economics*, 16(61), 273-310. 10.30495/fed.2023.698852
- Lashgarara, S., Khodadadi, V., Mazaheri, E. & Ayati Mehr, M. (2023). Assessing the risk of falling stock prices and its alignment with price bubbles based on the rational stock pricing structure. *Financial Accounting Research*, 15(3), 1-28. <https://doi.org/10.22108/far.2023.138880.1992> (in Persian)
- Lee, S. H., Bach, S. & Baik, Y.-S. (2011). The impact of IPOs on the values of directly competing incumbents. *Strategic Entrepreneurship Journal*, 5(2), 158-177. <https://doi.org/10.1002/sej.112>
- Li, J. & Li, Z. (2025). Mechanisms of corporate digital transformation on asymmetric capital structure adjustment—the mediating role of information asymmetry and financial stability. *Heliyon*, 11(3), e41745. <https://doi.org/10.1016/j.heliyon.2025.e41745>
- Li, S. (2023). Estimating stock market prices with histogram-based gradient boosting regressor: A case study on Alphabet Inc. *International Journal of Advanced Computer Science and Applications*, 15(5), 532-544. <https://doi.org/10.14569/IJACSA.2024.0150553>
- Lin, C. Y. & Marques, J. A. (2024). Stock market prediction using artificial intelligence: A systematic review of systematic reviews. *Social Sciences & Humanities Open*, 9(1), 100864. <https://doi.org/10.1016/j.ssaho.2024.100864>
- Liu, C., Yan, J., Guo, F. & Guo, M. (2022). Forecasting the market with machine learning algorithms: An application of NMC-BERT-LSTM-DQN-X algorithm in quantitative trading. *ACM Transactions on Knowledge Discovery from Data*, 16(4), 1-22. <https://doi.org/10.1145/3488378>
- López-Cabarcos, M. Á., Pérez-Pico, A. M., Vázquez Rodríguez, P. & López-Pérez, M. L. (2019). Investor sentiment in the theoretical field of behavioural finance. *Economic Research-Ekonomska Istraživanja*, 33(3), 1-19. <https://doi.org/10.1080/1331677X.2018.1559748>
- Malmir, F., Kheirollahi, F., Yarahmadi, H. & Sefaty, F. (2025). Application of gradient boosting algorithm in predicting relative pricing of initial public offerings: A case study of the Iranian stock exchange. *Business, Marketing, and Finance Open*, 2(5), 1-21. <https://www.bmfopen.com/index.php/bmfopen/article/view/236>
- Manosuri, A., Momeni, M. & Kazemi Miyangaskary, M. (2026). Integrating Stock Levels into Demand Forecasting and Discount Optimization for Retail. *Industrial Management Journal*, 18(2), 183-207.
- Naderi, Sh. & Espoukeh, J. (2016). Identify factors affecting on under pricing of initial public offering (IPO) shares of listed companies Tehran Stock Exchange. *Financial Knowledge of Securities Analysis*, 31, 97-109. <https://sid.ir/paper/200252/fa> (in Persian)

- Najafi, S., Bahrami, R. & Hosseini, N. (2023). Sentiment analysis and its impact on stock market volatility: Leveraging natural language processing techniques. *Accounting, Finance and Computational Intelligence*, 1(1), 13-27. <https://jafci.com/index.php/jafci/article/view/3> (in Persian)
- Nakagawa, K. & Yoshida, K. (2022). Time-series gradient boosting tree for stock price prediction. *International Journal of Data Mining, Modelling and Management*, 14(2), 110-125. <https://doi.org/10.1504/IJDMMM.2022.123357>
- Nasiri Aghdam, A., Jafari Shahrestani, A., Gholami, E. & Pirooz Rahi, Z. (2024). Lessons from Privatization of State-owned Enterprises in Iran A Case Study of Raja Passenger Train Company, Iran Airtour Airlines, Haft Tappeh Sugarcane Agro-industrial Company and Al Mahdi Aluminum Complex. *Majlis and Rahbord*, 31(118), 5-45. <https://doi.org/10.22034/mr.2023.5407.5162> (in Persian)
- Nikpey Pesyan, V., Reza Zadeh, A., Ahmadi Nezhad, H. & Ahmad Vand, S. (2023). Investigating the causal relationship between stocks' initial public offerings and macroeconomic variables. *Journal of Asset Management and Financing*, 11(2), 35-52. <https://doi.org/10.22108/amf.2023.136359.1779> (in Persian)
- Quintana, D., Sáez, Y. & Isasi, P. (2017). Random forest prediction of IPO underpricing. *Applied Sciences*, 7(6), 636. <https://doi.org/10.3390/app7060636>
- Rezaeyan, S., Taleghani, M. & Sherej Sharifi, A. (2024). Development of a comprehensive model to predict stock prices in the stock market with an interpretive structural modeling approach. *Journal of Asset Management and Financing*, 12(2), 39-58. <https://doi.org/10.22108/amf.2024.138983.1821> (in Persian)
- Ross, S. A. (1977). The determination of financial structure: The incentive-signalling approach. *The Bell Journal of Economics*, 8(1), 23-40. <https://doi.org/10.2307/3003485>
- Roy, S. S., Chopra, R., Lee, K. C., Spampinato, C. & Mohammadi-Ivatlood, B. (2020). Random forest, gradient boosted machines and deep neural network for stock price forecasting: A comparative analysis on South Korean companies. *International Journal of Ad Hoc and Ubiquitous Computing*, 33(1), 62-71. <https://doi.org/10.1504/IJAHUC.2020.104715>
- Saeidi Aghdam, M., Sadeghi, A., Bahiraie, A. & Haji Asghari, S. Y. (2023). Provide a stock price forecasting model using deep learning algorithms and its use in the pricing of Islamic bank stocks. *Islamic Economics & Banking*, 11(41), 5. <http://mieaoi.ir/article-1-964-fa.html> (in Persian)
- Schmitt, M. (2022). Deep learning vs. gradient boosting: Benchmarking state-of-the-art machine learning algorithms for credit scoring. *arXiv*. <https://doi.org/10.48550/arXiv.2205.10535>
- Shojaei, M., Abdolbaghi Ataabadi, A. & Shirvani, A. (2021). Investigating the effect of non – systematic fluctuations on mispricing: Evidence of Companies Listed in Tehran Stock Exchange. *Journal of Financial Accounting Research*, 12(4), 79-100. (in Persian)
- Subasi, A. (2020). Machine learning techniques. In *Practical Machine Learning for Data Analysis Using Python* (pp. 91-202). <https://doi.org/10.1016/B978-0-12-821379-7.00003-5>

- Taheri Haftasiabi, R. & Naderi, A. (2025). Earnings per share prediction and actual earnings management using optimal valuation of operating assets. *Public Sector Accounting and Budgeting*, 5(4), 138-164. <https://doi.org/10.22034/psab.2025.213907> (in Persian)
- Vaghfi, S. H., Sedighe, G., Parandin, K. & Hosseini Aghdaei, S. (2025). The role of ownership structure of stock in moderating the relationship between stock price concurrency and mispricing. *Journal of Management Accounting and Auditing Knowledge*, 14(55), 177-192. https://www.jmaak.ir/article_23622.html (in Persian)
- Vaidynathan, D., Kayal, P. & Maiti, M. (2025). A feature engineering based model architecture for modeling initial public offerings. *Applied Soft Computing*, 174, 113035.
- Vasić, A.S. (2020). The Importance of Initial Public Offering for Capital Market Development in Developing Countries. *Economic Themes* 58(1), 97-115. DOI:10.2478/ethemes-2020-0006
- Zareei, A., Falahi, M. A. & Maleksadati, S. S. (2024). The impact of international sanctions on Iran's economy with an emphasis on the role of the National Development Fund: DSGE model approach. *The Journal of Economic Policy*, 16(31), 35-80. <https://doi.org/10.22034/epj.2024.20548.2483>
- Zhang, J., Cai, K. & Wen, J. (2024). A survey of deep learning applications in cryptocurrency. *iScience*, 27(1), 108509. <https://doi.org/10.1016/j.isci.2023.108509>