Financial Research Journal

Print ISSN: 1024-8153
Online ISSN: 2423-5377

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. 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*)

Financial Research Journal, 2026, Vol. 28, No.3, pp. 885 - 932
Published by University of Tehran, College of Management
https://doi.org/10.22059/frj.2025.400625.1007779
Article Type: Research Paper
© Authors

Received: August 17, 2025
Revised: October 31, 2025
Accepted: December 04, 2025
Published online: October 01, 2026

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 R2 of 0.853 and a Root Mean Square Error (RMSE) of 0.497, representing a 60% improvement in prediction accuracy compared to Linear Regression (R2 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 R2 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.

شاپا چاپی: ۸۱۵۳-۱۰۲۴
شاپا الکترونیکی: ۵۳۷۷-۲۴۲۳

تحقیقات مالی

مدل‌سازی و پیش‌بینی بازده عرضهٔ اولیهٔ سهام با استفاده از الگوریتم‌های 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، دانشکدهٔ 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 توسعهٔ مدلی نوین مبتنی بر الگوریتم تقویت گرادیان و معماری ترانسفورمر برای پیش‌بینی دقیق نسبت‌های ارزش‌گذاری شرکت‌ها در زمان عرضهٔ اولیه سهام در بازار ایران انجام شده است. برخلاف رویکردهای سنتی که بر بازده روز اول تمرکز دارند، این پژوهش قیمت‌گذاری نسبی شرکت‌ها را از طریق سه نسبت کلیدی (ارزش بازار به ارزش دفتری، ارزش شرکت به کل دارایی‌ها و ارزش شرکت به فروش) ارزیابی می‌کند. با توجه به پیچیدگی‌های بازار ایران، شامل نوسان‌های شدید اقتصادی، تورم مزمن، تحریم‌های اقتصادی و محدودیت‌های نظارتی، این پژوهش برای سرمایه‌گذاران، پذیره‌نویسان و نهادهای نظارتی، ابزاری کارآمد به‌منظور تصمیم‌گیری آگاهانه‌تر ارائه می‌دهد.

روش: این مطالعه با رویکرد کمّی ـ کاربردی و با استفاده از داده‌های ۱۶۳ شرکت (۴۲ بورسی و ۱۲۱ فرابورسی) در بازهٔ ۱۳۹۲ تا ۱۴۰۲ انجام شد. این دوره شامل شرایط اقتصادی متنوع از جمله تحریم‌های شدید، نوسان‌های ارزی، رکود و رونق اقتصادی است. متغیرهای مستقل شامل ویژگی‌های مالی شرکت‌ها (اندازه، نسبت بدهی، سودآوری، بازده دارایی‌ها، حاشیهٔ سود، نسبت جریان نقدی، اهرم مالی و میانگین موزون هزینهٔ سرمایه) و متغیرهای کلان اقتصادی (نرخ تورم، شاخص کل بورس، شاخص تحریم، نرخ ارز و نرخ بهره) بودند. معماری پیشنهادی، ترکیبی از الگوریتم‌های درختی تقویت گرادیان، شبکه‌های حافظهٔ طولانی ـ کوتاه‌مدت و سازوکارهای خودتوجهی است که از طریق جست‌وجوی خودکار معماری بهینه‌سازی شد. پارامترهای بهینه عبارت‌اند از: میزان یادگیری ۰/۰۰۱ و صدوپنجاه درخت

استناد: مالمیر، فاطمه؛ خیراللهی، فرشید؛ یاراحمدی، حسین و صفتی، فرید (۱۴۰۵). مدل‌سازی و پیش‌بینی بازده عرضهٔ اولیهٔ سهام با استفاده از الگوریتم‌های یادگیری ماشین تقویت گرادیان. *تحقیقات مالی*، ۲۸(۳)، ۸۸۵- ۹۳۲.

تحقیقات مالی، ۱۴۰۵، دوره ۲۸، شماره ۳، صص. ۸۸۵- ۹۳۲
ناشر: دانشکدگان مدیریت دانشگاه تهران
نوع مقاله: علمی پژوهشی
© نویسندگان

تاریخ دریافت: ۱۴۰۴/۰۵/۲۶
تاریخ ویرایش: ۱۴۰۴/۰۸/۰۹
تاریخ پذیرش: ۱۴۰۴/۰۹/۱۳
تاریخ انتشار: ۱۴۰۵/۰۷/۰۹
doi: https://doi.org/10.22059/frj.2025.400625.1007779

تصمیم، چهار گام زمانی و سه لایهٔ خودتوجهی. مدل با روش‌های سنتی (رگرسیون خطی) و پیشرفته (الگوریتم‌های تقویت گرادیان استاندارد، جنگل تصادفی و شبکه‌های عصبی بازگشتی) مقایسه و از طریق روش اعتبارسنجی متقابل ده‌تایی و بوت‌استرپ، اعتبارسنجی شد.

یافته‌ها: نتایج پژوهش برتری قاطع مدل پیشنهادی را در پیش‌بینی هر سه نسبت ارزش‌گذاری نشان داد. برای نسبت ارزش بازار به ارزش دفتری، مدل توسعه‌یافته با ضریب تعیین ۰/۸۵۳ و ریشهٔ میانگین مربعات خطای ۰/۴۹۷، نسبت به رگرسیون خطی (ضریب تعیین ۰/۵۳۴)، به بهبود ۶۰ درصدی در دقت پیش‌بینی دست یافت. در پیش‌بینی نسبت ارزش شرکت به کل دارایی‌ها، ضریب تعیین ۰/۸۶۵ و کاهش ۶۹ درصدی میانگین مربعات خطا (از ۰/۱۵۲ به ۰/۰۴۷) به‌دست آمد. برای نسبت ارزش شرکت به فروش نیز با ضریب تعیین ۰/۸۴۶، بهبود ۶۷ درصدی در دقت نسبت به روش‌های سنتی مشاهده شد. سایر مدل‌های پیشرفته نیز عملکرد درخور توجهی داشتند؛ اما به سطح مدل پیشنهادی نرسیدند. آزمون‌های اعتبارسنجی متقابل، پایداری بسیار خوب مدل را با انحراف معیار بسیار پایین (در حدود ۰/۰۱) تأیید کرد که نشان‌دهندهٔ قابلیت تعمیم‌پذیری و اعتمادپذیری مدل در شرایط مختلف است. تحلیل اهمیت متغیرها نشان داد که میزان تورم با میانگین اهمیت ۰/۱۹، به‌عنوان دومین عامل مهم در تمامی مدل‌ها عمل می‌کند که بیانگر تأثیر عمیق شرایط اقتصادی کلان بر ارزش‌گذاری شرکت‌ها در بازار ایران است. بازده دارایی‌ها با اهمیت ۰/۲۱ برای نسبت ارزش بازار به ارزش دفتری، حاشیهٔ سود با اهمیت ۰/۲۲۵ برای نسبت ارزش شرکت به فروش و نسبت جریان نقدی به دارایی‌ها با اهمیت ۰/۲ برای نسبت ارزش شرکت به دارایی‌ها، به‌عنوان مهم‌ترین شاخص‌های عملکرد مالی شناسایی شدند.

نتیجه‌گیری: یافته‌ها بر اهمیت به‌کارگیری تکنیک‌های نوین یادگیری ماشین در پیش‌بینی نسبت‌های ارزش‌گذاری عرضه‌های اولیه تأکید دارد. مدل توسعه‌یافته با کاهش ۶۰ تا ۶۹ درصدی خطای پیش‌بینی، ابزاری پیشرفته برای پذیره‌نویسان، سرمایه‌گذاران و مدیران سرمایه فراهم می‌آورد تا ریسک کم‌ارزش‌گذاری یا بیش‌ارزش‌گذاری را کاهش دهند. شناسایی نقش محوری نرخ تورم نشان‌دهندهٔ حساسیت بسیار زیاد ارزش‌گذاری‌ها به شرایط کلان اقتصادی در بازار ایران است. این پژوهش در سه حوزهٔ کلیدی مشارکت دارد: معرفی معماری نوین ترکیبی، ارائه چارچوب جامع اعتبارسنجی و شناسایی تفاوت‌های اهمیت متغیرها برای نسبت‌های مختلف ارزش‌گذاری در شرایط اقتصادی ناپایدار.

کلیدواژه‌ها: پیش‌بینی، عرضهٔ اولیه سهام، الگوریتم تقویت گرادیان، یادگیری ماشین، بازار سرمایهٔ ایران.

مقدمه

عرضهٔ اولیه سهام[1] به‌عنوان 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[2]، ۲۰۲۵). این فرایند استراتژیک، نقطهٔ عطفی در چرخهٔ 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 مارزلو، ۱۳۹۰).

مسئلهٔ اصلی این پژوهش ناکارآمدی روش‌های سنتی قیمت‌گذاری عرضه‌های اولیه سهام در بازار سرمایهٔ ایران است که به زیان‌های درخور توجه برای سرمایه‌گذاران و عدم تخصیص بهینهٔ منابع منجر می‌شود (شجاعی، عبدالباقی عطاآبادی و شیروانی، ۱۳۹۹). قیمت‌گذاری صحیح عرضه‌های اولیهٔ 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 پدیدهٔ 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[3]، ۲۰۲۰؛ جمعانی و علی دروس[4]، 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 نشان‌دهندهٔ عدم قطعیت در ارزش‌گذاری و وجود ریسک‌های پیش‌بینی‌نشده است (فولبرون، نوگباور و نیکلیش[5]، 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[6]، ۲۰۱۰؛ ایبوتسون، سیندلار و ریتر[7]، ۱۹۹۴).

مشکل اساسی در بازار سرمایهٔ ایران این است که علاوه‌بر 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 سرمایهٔ ایران را به‌طور بنیادی تغییر داده است (قاسمی‌نژاد و جهان‌پرور[1]، ۲۰۲۱؛ حیدریان، پهلوانی و میرجلیلی[2]، ۲۰۲۵؛ زارعی، فلاحی و ملک سعادتی[3]، ۲۰۲۴). در بازار سرمایهٔ 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 آیتی مهر، ۱۴۰۲؛ رضاییان، طالقانی و شرج شریفی، ۱۴۰۳؛ غفاری، عرب‌زاده، صفری گرایلی، جباری و رضایی پیته‌نویی[4]، ۲۰۲۳). این تحریم‌ها باعث ایجاد پدیده‌های خاصی در بازار سرمایهٔ 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 ـ اقتصادی» نشئت‌گرفته 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 توسعهٔ 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 عرضهٔ اولیهٔ 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 (وایدیناتان، کایال و مایتی[5]، ۲۰۲۵ ؛ کینتانا، سائز و ایساسی[6]، ۲۰۱۷؛ افشاری راد، 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[7]، ۲۰۲۰؛ خان، چاودری و چاندرا[8]، ۲۰۲۴).

از جنبهٔ 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 حسینی عقدایی، ۱۴۰۴؛ دریایی، عزیزی و فتاحی[9]، ۲۰۲۲).

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

ریسک تحریمی، به‌عنوان عاملی منحصربه‌فرد در بازار سرمایهٔ ایران، از طریق کانال‌های مختلفی شامل محدودیت دسترسی به منابع ارزی، افزایش هزینه‌های تأمین مواد اولیه، عدم امکان انتقال تکنولوژی و محدودیت در بازارهای صادراتی، بر ارزش‌گذاری شرکت‌ها تأثیر می‌گذارد (عابدیان و موسوی، ۱۴۰۳). بنابراین، ویژگی‌های خاص بازار سرمایهٔ ایران از جمله عدم شفافیت اطلاعاتی، ضعف در حاکمیت شرکتی، نوسان‌های اقتصادی، تغییرات نرخ ارز و رفتار متمایز سرمایه‌گذاران که اغلب تحت تأثیر عوامل روانی و هیجانی قرار می‌گیرند، در کنار اثرهای روانی ناشی از تحریم‌ها و انزوای بین‌المللی که به بی‌اعتمادی و رفتارهای گله‌ای در بازار منجر می‌شود، ضرورت توسعهٔ مدل‌های بومی با قابلیت تحلیل ریسک و عدم قطعیت برای پیش‌بینی دقیق بازده عرضه‌های اولیه را دوچندان می‌کند (خاتمی، زمردیان، فلاح شمس لیالستانی و مینوئی، ۱۴۰۱؛ حسینی، ابراهیمی سروعلیا، امیری و پیمانی فروشانی، ۱۴۰۲).

پیشرفت‌های اخیر در حوزهٔ هوش مصنوعی و یادگیری ماشین، افق‌های جدیدی را برای مدیریت ریسک و تحلیل عدم قطعیت در بازارهای مالی گشوده است که به نیازهای موجود در قیمت‌گذاری عرضه‌های اولیه در شرایط پُرریسک و تحت تحریم، پاسخی مناسب ارائه می‌دهد (عباس‌حسن، پیری و چالاکی، ۱۴۰۴؛ گان، ونگ و یانگ[1]، ۲۰۲۰). الگوریتم تقویت گرادیان، به‌طور خاص با توانایی مدیریت داده‌های پیچیده، تحلیل سناریوهای ریسک، شناسایی الگوهای غیرخطی و ترکیب متغیرهای متعدد در محیط‌های پُرنوسان و غیرقطعی و قابلیت یادگیری از داده‌های محدود و نویزی که مشخصه بازارهای تحت تحریم است، گزینه‌ای مناسب برای مدل‌سازی قیمت‌گذاری عرضه‌های اولیه محسوب می‌شود (عباسیان، شهرکی، فلاح‌پور و نمکی، ۱۴۰۲). مطالعات بین‌المللی نیز تأیید می‌کنند که استفاده از این الگوریتم‌ها می‌تواند با در نظر گرفتن عوامل ریسک و عدم قطعیت، دقت پیش‌بینی قیمت و بازده عرضه‌های اولیه را به میزان شایان توجهی افزایش دهد (بابا و سویل[2]، ۲۰۲۰؛ لین و مارکوس[3]، ۲۰۲۴). بنابراین، اهمیت و ضرورت توسعه مدل‌های پیش‌بینی دقیق برای عرضه‌های اولیه در بازار سرمایهٔ ایران از ابعاد مختلف زیر قابل تبیین است:

نخست، با توجه به تحریم‌های بین‌المللی و محدودیت‌های دسترسی به بازارهای جهانی سرمایه، بازار داخلی در تأمین مالی بنگاه‌های اقتصادی نقش حیاتی ایفا می‌کند و بهبود کارایی عرضه‌های اولیه، می‌تواند به تقویت این نقش کمک شایانی کند (رضاییان و همکاران، ۱۴۰۳).

دوم، در شرایط انزوای اقتصادی و عدم امکان جذب سرمایه‌گذاری مستقیم خارجی، عرضه‌های اولیه به یکی از معدود گزینه‌های باقی‌مانده برای تأمین مالی شرکت‌ها تبدیل شده است که اهمیت قیمت‌گذاری صحیح آن‌ها را دوچندان می‌کند.

سوم، در شرایط تورم مزمن و کاهش ارزش پول ملی که تشدید آن ناشی از تحریم‌ها و کاهش درآمدهای ارزی است، عرضه‌های اولیه موفق می‌توانند به‌عنوان ابزاری برای حفظ ارزش دارایی‌های مردم و هدایت نقدینگی سرگردان به سمت بخش‌های مولد اقتصاد عمل کنند (خدیوی، بحری ثالث، جبارزاده کنگرلویی و زواری رضایی[4]، 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، توسعهٔ 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 استارتاپ‌ها و شرکت‌های دانش‌بنیان که بسیاری از آن‌ها به‌دلیل 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، توسعهٔ چنین مدل‌هایی می‌تواند با کاهش عدم قطعیت ناشی از تحریم‌ها و ارائهٔ تصویری شفاف‌تر از ریسک‌های موجود، به ارتقای جایگاه بازار سرمایهٔ 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 عرضهٔ اولیهٔ سهام با در نظر گرفتن شرایط عدم قطعیت، ریسک‌های چندگانه و نوسان‌های ساختاری در بازار سرمایهٔ 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 سرمایهٔ ایران، دقت پیش‌بینی بازده عرضه‌های اولیهٔ سهام را در مقایسه با روش‌های سنتی که عمدتاً بر فرض‌های ساده‌انگارانه و شرایط ایدئال مبتنی هستند، به‌طور معناداری بهبود بخشد؟ همچنین این پژوهش به‌دنبال شناسایی مهم‌ترین عوامل ریسک و عدم قطعیت مؤثر بر عملکرد عرضه‌های اولیه در بازار ایران و ارائهٔ 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 عرضهٔ اولیهٔ سهام، تشریح روش جمع‌آوری داده‌ها و مدل‌سازی، ارائهٔ 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 پیشینهٔ پژوهش

عرضهٔ اولیهٔ سهام[1]، 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 عرضهٔ اولیهٔ سهام، به قرن

1. Initial Public Offering - IPO

هفدهم میلادی و شرکت هلندی[1] بازمی‌گردد (واسیچ[2]، ۲۰۲۰؛ درودوین[3]، ۲۰۲۳). از منظر تئوریک، عرضهٔ اولیهٔ سهام، نمادی از انتقال مالکیت از حوزهٔ خصوصی به عمومی محسوب می‌شود که با چالش‌های اساسی نظیر عدم تقارن اطلاعاتی، مسئلهٔ نمایندگی و ارزش‌گذاری دشوار همراه است (کامیابی و بوربوری، ۱۳۹۵).

تئوری‌های کلاسیک مالی شامل سه رکن اصلی هستند:

اول، نظریهٔ بازار کارآمد فاما[4] (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، نظریهٔ سیگنال‌دهی راس[5] (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، پدیدهٔ قیمت‌گذاری پایین‌تر از حد انتظار[6] که توسط ایبوتسون[7] (۱۹۷۵) مستندسازی شد و نخستین تناقض جدی با فرضیه‌های بازار کارآمد را آشکار ساخت، نشان‌دهندهٔ نیاز به رویکردهای جدیدتر در مدل‌سازی است.

از طرفی دیگر، تحولات نظری مدرن در حوزه عرضهٔ اولیهٔ سهام بر پیچیدگی‌های اطلاعاتی و رفتاری متمرکز شده‌اند که خلأهای نظری تئوری‌های کلاسیک را برطرف می‌سازند؛ به‌گونه‌ای که نظریهٔ مزایدهٔ کتابچه‌سازی[8] توسط بنونیست و اسپیندت[9] (۱۹۸۹) با وجود توضیح سازوکار قیمت‌گذاری پویا، در عمل نتوانسته است دقت پیش‌بینی مناسبی ارائه دهد. مطالعات درین و وواماک[10]، (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[11] بیکر و ورگلر[12] (۲۰۰۶) و نظریهٔ گله‌وارگی (نظریهٔ هردینگ[13])، تصمیم‌گیری روان‌شناختی در بازار عرضهٔ اولیهٔ سهام را برجسته می‌سازد (لوپز کابارکوس، پرز پیکو، وازکز رودریگز و لوپز پرز،[14] ۲۰۱۹). با این حال، این نظریه‌ها عمدتاً توصیفی بوده و فاقد قدرت پیش‌بینی کمّی 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[15]، 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[1]، 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 پایهٔ کارهای فریدمن[2] (۲۰۰۱) در گرادیان تقویتی[3] و توسعه‌های بعدی چن و گسترین[4] (۲۰۱۶) و کِی و همکاران[5] (۲۰۱۷) در ماشین بسیار سریع تقویتی گرادیان[6] 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[7]، ۲۰۲۲). در حوزهٔ مالی، این قابلیت‌ها امکان درنظرگیری هم‌زمان صدها متغیر تأثیرگذار بر بازده عرضهٔ اولیهٔ سهام، از شاخص‌های کلان اقتصادی تا ویژگی‌های خُرد شرکت و احساسات بازار را فراهم می‌آورد (دوآن و همکاران[8]، ۲۰۱۶).

همگرایی نظریه‌های مالی مدرن با الگوریتم‌های تقویت گرادیان، چارچوب جامعی برای درک و پیش‌بینی بازده عرضهٔ اولیهٔ سهام ارائه می‌دهد که هم در تئوری‌های اقتصادی ریشه دارد و هم از قدرت محاسباتی مدرن بهره می‌برد (ژانگ، کای و ون[9]، 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 کمّی؛ سوم، محدودیت روش‌های سنتی در پردازش حجم بالای داده‌ها (لیو، یان، گو و گو[10]، ۲۰۲۲). علاوه‌بر این، قابلیت تقویت گرادیان در مدیریت عدم قطعیت و نوفه بازار، آن را به ابزاری مناسب برای مواجهه با ماهیت احتمالاتی و پویای بازده عرضهٔ اولیهٔ سهام تبدیل می‌کند (عباسیان و همکاران، ۱۴۰۲). این همگرایی نه‌تنها دقت پیش‌بینی را افزایش می‌دهد، بلکه درک عمیق‌تری از سازوکارهای اساسی تأثیرگذار بر عملکرد عرضهٔ اولیهٔ سهام ارائه می‌دهد و زمینه را برای توسعه استراتژی‌های سرمایه‌گذاری پیشرفته و سیاست‌گذاری‌های نظارتی مؤثرتر فراهم می‌آورد (لی و لی[11]، 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[1] و تحلیل احساسات، افق‌های جدیدی در پیش‌بینی بازده عرضهٔ اولیهٔ 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[2] و پردازش بی‌درنگ اطلاعات، زمینه‌ساز ایجاد نسل جدیدی از سیستم‌های پیش‌بینی هوشمند است که نه‌تنها دقت بسیار زیادی دارند، بلکه قابلیت دارند تا با شرایط متغیر بازار و ارائهٔ توضیحات منطقی برای تصمیم‌های خود تطبیق یابند (آل احمدی[3]، ۲۰۲۵؛ لین و مارکوس، ۲۰۲۴).

در خصوص پیش‌بینی بازده عرضهٔ اولیهٔ سهام مطالعات تجربی متعددی وجود دارد که در ادامه مورد بررسی قرار گرفته است. روی، چوپرا، لی، اسپمپیناتو و محمدی ایواتلود[4] (۲۰۲۰) در مطالعه‌ای با عنوان «جنگل تصادفی، ماشین‌های گرادیان بوستینگ و شبکهٔ عصبی عمیق برای پیش‌بینی قیمت سهام: تحلیل مقایسه‌ای روی شرکت‌های کره جنوبی»، به مقایسهٔ روش‌های مختلف یادگیری ماشین در پیش‌بینی قیمت سهام پرداختند. آن‌ها یک رویکرد مبتنی بر شبکهٔ 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 نقطهٔ ضعف کلیدی این مطالعه، بی‌توجهی به ویژگی‌های خاص بازار IPO و تمرکز صرف بر بازار ثانویه بود. همچنین، استفاده از شبکهٔ عصبی عمیق با وجود دقت بالا (AUC = ۰/۸۰۶)، مشکل جعبهٔ 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 «ارائهٔ مدل پیش‌بینی قیمت سهام با استفاده از الگوریتم‌های یادگیری عمیق و کاربرد آن در قیمت‌گذاری سهام بانک‌های اسلامی»، به ارائهٔ مدلی ترکیبی برای پیش‌بینی روند حرکتی قیمت سهام با استفاده از شبکهٔ 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[5] (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 نشان‌دهندهٔ 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 ارزش‌گذاری نسبی محسوب می‌شود؛ اما فاقد تمرکز خاص بر IPO است. همچنین، عدم استفاده از الگوریتم‌های تقویت گرادیان پیشرفته و اکتفا به روش‌های پایه‌ای یادگیری ماشین، فرصتی از دست رفته برای بهبود دقت پیش‌بینی است.

از سویی دیگر، ناکاگاوا و یوشیدا[1] (۲۰۲۲) در مقاله‌ای با عنوان «درخت گرادیان بوستینگ سری زمانی برای پیش‌بینی قیمت سهام»، یک روش گرادیان بوستینگ درختی مبتنی بر سری‌های زمانی برای مجموعه داده‌هایی با ویژگی‌های سری زمانی و مقطعی پیشنهاد دادند. مدل آن‌ها دارای یادگیرنده‌های ضعیف با ویژگی‌های سری زمانی و مقطعی در گره‌های داخلی است که نمونه‌ها را بر اساس شباهت بین جفت سری‌های زمانی یا ناخالصی بین ویژگی‌های مقطعی تقسیم می‌کند. آن‌ها با تحلیل تجربی روی شاخص‌های اصلی جهانی نشان دادند که روش پیشنهادی از نظر سودآوری و دقت نسبت به روش‌های قبلی برتری دارد. نوآوری کلیدی این مطالعه، ترکیب ویژگی‌های 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 می‌سازد.

لی[2] (۲۰۲۳) در مطالعه‌ای با عنوان «تخمین قیمت‌های بازار سهام با رگرسور تقویت گرادیان مبتنی بر هیستوگرام: مطالعه موردی روی شرکت الفبت[3]» به تخمین قیمت‌های سهام با استفاده از رگرسور تقویت گرادیان مبتنی بر هیستوگرام پرداخت. یافته‌ها نشان‌دهندهٔ بهبود چشمگیری در دقت در مقایسه با مدل‌های سنتی تقویت گرادیان بود. قدرت ترکیبی[4] و تکنیک‌های بهینه‌سازی مختلف از جمله بهینه‌سازی ازدحام ذرات، الگوریتم کپک مخاطی و بهینه‌سازی گرگ خاکستری، نه‌تنها دقت پیش‌بینی را افزایش داد، بلکه توانایی مدل را برای تطبیق با شرایط متغیر بازار تقویت کرد. این مطالعه نشان داد که الگوریتم‌های تقویت گرادیان مبتنی بر هیستوگرام (مانند LightGBM) سرعت محاسباتی را تا ۲۰ برابر افزایش می‌دهند، در حالی که دقت را حفظ می‌کنند. این مزیت برای تحلیل بی‌درنگ IPO حیاتی است؛ اما محدودیت اصلی، تمرکز بر یک شرکت منفرد (الفبت) است که تعمیم‌پذیری یافته‌ها را محدود می‌کند.

در ادامه هراتمه و ابراهیمی (۱۴۰۲) در پژوهشی با عنوان «بررسی تأثیر عرضه عمومی و اولیه سهام بر عملکرد مالی شرکت‌ها»، به بررسی تأثیر عرضهٔ عمومی اولیهٔ سهام بر عملکرد مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداختند. در این مطالعه از طریق نمونه‌گیری غربالگری از بین ۴۵۸ شرکت در دورهٔ زمانی ۱۳۹۸ تا ۱۴۰۲، تعداد ۱۳۲ شرکت به‌عنوان نمونه انتخاب و با رویکرد پنل دیتا برای ۶۶۰ مشاهده (سال ـ شرکت) الگوی رگرسیونی چندمتغیره برآورد شد. نتایج این پژوهش نشان داد که عرضهٔ عمومی تأثیر منفی اما غیرمعناداری بر نسبت سود خالص به کل دارایی‌ها دارد که تأثیر منفی عرضهٔ عمومی بر عملکرد مالی شرکت‌ها را نشان می‌دهد و این ضریب از نظر آماری معنادار بوده است. اگرچه این مطالعه بینش‌های ارزشمندی دربارهٔ تأثیر منفی IPO بر عملکرد کوتاه‌مدت ارائه داد؛ اما دو

1. Nakagawa & Yoshida
2. Li
3. Alphabet
4. HGBoost

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[1] (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[2] بهینه‌شده، با استفاده از الگوریتم بهینه‌سازی هیبریدی هریس هاوک[3] برای پیش‌بینی تجارت ارائه دادند. آن‌ها مشکل بیش‌برازش در بهینه‌سازی متعارف هریس هاوک را با استفاده از روش‌های دسته‌بندی ویژگی انحصاری[4] و نمونه‌برداری یک‌طرفه مبتنی بر گرادیان[5] برطرف کردند. نتایج نشان داد که پارامترهای ورودی در پیش‌بینی رشد اقتصادی در رابطه با سیستم تجارت بین‌بازاری[6] 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 شبکهٔ مالی و روش ترکیبی درخت تصمیم تقویت گرادیان»، به بررسی عملکرد الگوی درخت تصمیم تقویت گرادیان با افزودن متغیرهای مربوط به شبکهٔ مالی پرداختند. آن‌ها الگوی پیشنهادی خود را روی داده‌های ۱۲۳ شرکت تولیدی پذیرفته شده در بورس و فرابورس ایران در بازهٔ زمانی ۲۰۱۵ تا ۲۰۲۱ اجرا کردند. نتایج نشان داد که الگوی درخت تصمیم تقویت گرادیان با اضافه شدن متغیرهای مربوط به شبکهٔ 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 درجهٔ 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 پسیان و همکاران (۲۰۲۳) در پژوهشی با عنوان «بررسی رابطهٔ علیت بین عرضهٔ اولیهٔ سهام و عوامل کلان اقتصادی»، به بررسی رابطهٔ 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[7]، طی دورهٔ زمانی ۱۳۷۰ تا ۱۳۹۸ استفاده کردند. یافته‌های این پژوهش نشان داد که تعداد عرضه‌های اولیهٔ، 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

عرضهٔ 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 اولیهٔ شرکت‌ها، همه نباید صرف هزینهٔ 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 پُر 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 نیشت[1] (۲۰۲۴) در پژوهشی به بررسی کاربرد ماشین تقویت گرادیان سبک[2] 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 ارائهٔ 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 ۳۰درصد 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[3] (۲۰۲۵) در مطالعه‌ای با عنوان «پیش‌بینی بازارهای سهام[4] 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[5] پرداختند. این تحلیل، مقادیر توضیح افزودنی شپلی 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. نقطهٔ قوت این مطالعه، ادغام شاخص‌های ESG و استفاده از SHAP برای تفسیرپذیری است. نتایج نشان داد که تقویت گرادیان در مقایسه با رگرسیون خطی، ۱۲درصد 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

ملامیر، خیراللهی، یاراحمدی و صفتی[1] (۲۰۲۵). بـه توسـعهٔ مـدلی مبتنـی بـر الگـوریتم گرادیـان بوسـتینگ بـرای پیش‌بینی قیمت‌گذاری نسبی عرضه‌های اولیه عمومی در بازار سهام ایران پرداختند. این مطالعه نزدیک‌ترین پـژوهش بـه 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، عـدم اسـتفاده از معماری‌هـای پیشـرفته ترکیبـی؛ دوم، تمرکز بر یک متغیر وابسته؛ سوم، عدم ادغام تحلیل احساسات و داده‌های جایگزین.

منصوری، مؤمنی و کاظمی میان گسکری[2] (۲۰۲۶) در پژوهش خود به این موضوع پرداختند کـه پیش‌بینـی دقیـق فروش برای مدیریت موجودی و برنامه‌ریزی زنجیرهٔ تأمین در محیط‌های خرده‌فروشی با تنـوع بـالای محصـول، چرخـهٔ عمر کوتاه و تقاضای ناپایدار بسیار مهم است. خطاها باعث موجـودی اضـافی، اتمـام موجـودی، فـروش از دسـت رفتـه، تبلیغات غیربهینه، هزینه‌های بالاتر، کاهش رضایت مشتری و آسیب به برند می‌شوند. پیش‌بینی‌های قابل اعتمـاد، باعـث افزایش موجودی، قیمت‌گذاری، طراحی تبلیغات، تخصیص موجودی و سودآوری می‌شوند. از آنجایی که خرده‌فروشـان از استراتژی‌های مبتنی بر داده استقبال می‌کنند، مدل‌ها باید تعاملات بین تقاضا، قیمت‌گذاری و موجودی را در نظر بگیرند. این مطالعه یک چارچوب شبکهٔ عصبی عمیق را معرفی می‌کند که به‌طور مشترک پیش‌بینی تقاضا و بهینه‌سازی تخفیـف 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 انجـام ایـن پژوهش را توجیه می‌کند. نخستین شکاف، فقدان مدل‌های یکپارچه و چندبُعدی برای قیمت‌گـذاری نسـبی عرضـهٔ اولیـهٔ سهام است. مطالعات بین‌المللی همچون روی و همکاران (۲۰۲۰)، ناکاگـاوا و یوشـیدا (۲۰۲۲) و لـی (۲۰۲۳)، عمـدتاً بـر پیش‌بینی قیمت سهام در بازار ثانویه متمرکز بوده‌انـد و ویژگی‌هـای منحصـربه‌فرد بـازار عرضـهٔ اولیـهٔ سـهام، از جملـه عدم‌تقارن اطلاعاتی شدید، محدودیت داده‌های تاریخی و رفتار متمایز سـرمایه‌گذاران را نادیـده گرفته‌انـد. حتـی مطالعـه ملامیر و همکاران (۲۰۲۵) که به صراحت بر عرضهٔ اولیهٔ سهام در ایران تمرکز دارد، تنها به یـک شـاخص ارزش‌گـذاری (نسبت M2B) محدود مانده و از تحلیل هم‌زمان چندین معیار قیمت‌گذاری نسـبی کـه بـرای درک کامـل سـازوکارهای ارزش‌گذاری ضروری است، غافل شده است. این در حالی است که نظریه‌های مالی مدرن بر لزوم استفاده از رویکردهـای چندشاخصی برای کاهش خطای برآورد و افزایش دقت ارزش‌گذاری تأکید دارند.

دومین شکاف محـوری، محـدودیت معماری‌هـای الگـوریتمی مـورد اسـتفاده در مطالعـات پیشـین اسـت. اگرچـه پژوهش‌هایی نظیر گوپتا و کومـار (۲۰۲۳) و هومـا و نیشـت (۲۰۲۴) از الگوریتم‌هـای تقویـت گرادیـان پیشـرفته ماننـد 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، فاقـد

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 سرمایهٔ ایران توسعه نیافته‌اند. این شکاف، نیاز به طراحی معماری‌های هیبریدی و چندلایه‌ای را که بتوانند پیچیدگی‌های ذاتی داده‌های مالی عرضهٔ اولیهٔ سهام را مدل‌سازی کنند، برجسته می‌سازد.

سومین شکاف تحقیقاتی، بی‌توجهی به تفسیرپذیری و شفافیت مدل‌های پیشنهادی در حوزهٔ پیش‌بینی عرضهٔ اولیهٔ 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 شپلی برای افزایش تفسیرپذیری استفاده کرده‌اند؛ اما این رویکرد در بستر عرضهٔ اولیهٔ سهام و با الگوریتم‌های پیشرفته ترکیبی در ایران به‌کار گرفته نشده است. همچنین، مطالعات داخلی نظیر هراتمه و ابراهیمی (۱۴۰۲) و نیک‌پی‌پسیان و همکاران (۱۴۰۳) به بررسی عوامل مؤثر بر عرضهٔ اولیهٔ 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 به‌صورت سیستماتیک متغیرهای کلان اقتصادی، ویژگی‌های خاص شرکت و شرایط بازار را در قالب چارچوب یکپارچه برای پیش‌بینی چندشاخصی عرضهٔ اولیهٔ سهام ادغام نکرده‌اند. این شکاف، نیاز به یک مطالعه جامع با نمونهٔ گسترده، دورهٔ زمانی طولانی و رویکرد چندمتغیره را که ویژگی‌های منحصربه‌فرد بازار سرمایهٔ ایران را در نظر بگیرد، آشکار می‌سازد.

این پژوهش با هدف پُرکردن شکاف‌های شناسایی‌شده، چهار نوآوری بنیادین و شایان توجه را معرفی می‌کند که مرزهای دانش موجود در حوزه قیمت‌گذاری نسبی عرضهٔ اولیهٔ سهام را گسترش می‌دهد. نخستین نوآوری، توسعهٔ معماری پیشرفته ترانسفورمر تقویت‌کنندهٔ گرادیان عمیق است که برای نخستین بار در حوزهٔ قیمت‌گذاری نسبی عرضهٔ اولیهٔ سهام به‌کار 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. لایهٔ درخت‌های رگرسیون افزایشی چندگانه که قابلیت استخراج الگوهای غیرخطی پیچیده و تعاملات

مرتبه بالای متغیرها را فراهم می‌آورد؛ ۲. لایهٔ 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 به‌صورت خودکار ترکیب‌های بهینه از ویژگی‌های ورودی را کشف و تولید می‌کند. این ترکیب نوآورانه، توانایی مدل‌سازی هم‌زمان تعاملات چندبُعدی، الگوهای زمانی و روابط غیرخطی را که در روش‌های سنتی و حتی مطالعات اخیر نظیر ناکاگاوا و یوشیدا (۲۰۲۲) و لی (۲۰۲۳) غفلت می‌شود، به‌طور قابل ملاحظه‌ای ارتقا می‌بخشد و معماری‌ای ارائه می‌دهد که برای ویژگی‌های خاص داده‌های عرضهٔ اولیهٔ سهام شامل نویز بالا، عدم‌تقارن اطلاعاتی و محدودیت تاریخچه، 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 عرضهٔ اولیهٔ سهام ایران مورد بررسی قرار می‌گیرد. مطالعات پیشین همچون گیرتسما 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 به‌کارگیری ماژول تبدیل پویای ویژگی و جست‌وجوی معماری شبکهٔ عصبی مبتنی بر گرادیان، نه‌تنها قادر به پیش‌بینی دقیق هریک از این سه شاخص به‌صورت مستقل است، بلکه همچنین روابط سیستماتیک و تعاملات پویا بین آن‌ها را کشف و مدل‌سازی می‌کند. این رویکرد جامع، درک عمیق‌تری از سازوکارهای چندبُعدی قیمت‌گذاری در عرضهٔ اولیهٔ سهام ارائه می‌دهد، امکان تحلیل تطبیقی عملکرد مدل در شرایط مختلف بازار (صعودی، نزولی و خنثی) را فراهم می‌آورد و ابزاری کامل برای تصمیم‌گیری چندبُعدی 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 سرمایهٔ ایران است. این پژوهش با استفاده از داده‌های جامع ۱۶۳ شرکت در بازه زمانی گسترده ۱۳۹۲ تا ۱۴۰۲ که شامل سه چرخهٔ کامل اقتصادی (رونق، رکود و تعدیل) می‌شود، نه‌تنها 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 به‌صورت تکاملی و خودتطبیقی انجام می‌شود.

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

محدودیت پیچیدگی محاسباتی بالا و زمان‌بر بودن مواجه بوده‌اند. این پژوهش یک استراتژی بهینه‌سازی سه‌مرحله‌ای را پیاده‌سازی می‌کند:

۱. مرحله کاوش اولیه با استفاده از الگوریتم ژنتیک اصلاح‌شده که فضای جست‌وجوی گسترده فراپارامترها را به‌صورت موازی کاوش می‌کند؛

۲. مرحلهٔ بهره‌برداری متمرکز با استفاده از بهینه‌سازی بیزین که مناطق امیدوارکننده را با دقت بالاتر بررسی می‌کند؛

۳. مرحلهٔ تنظیم دقیق با استفاده از الگوریتم جست‌وجوی شبکه‌ای تطبیقی که پارامترهای نهایی را با توجه به ویژگی‌های خاص هر متغیر وابسته بهینه می‌کند.

این سیستم بهینه‌سازی سلسله‌مراتبی، زمان محاسباتی را تا ۶۰درصد کاهش می‌دهد در حالی که دقت مدل را حداقل ۸ درصد نسبت به روش‌های بهینه‌سازی سنتی افزایش می‌دهد. علاوه‌براین، استفاده از تکنیک‌های منظم‌سازی پیشرفته شامل Dropout تطبیقی، منظم‌سازی L1/L2 ترکیبی و Early Stopping هوشمند، از بیش‌برازش جلوگیری و تعمیم‌پذیری مدل را در داده‌های جدید تضمین می‌کند. در مجموع، این چهار نوآوری به‌صورت سینرژیک با یکدیگر تعامل می‌کنند تا یک چارچوب جامع، کارآمد و قابل تفسیر برای قیمت‌گذاری نسبی عرضهٔ اولیهٔ سهام در بازار سرمایهٔ ایران ارائه دهند. این پژوهش نه‌تنها شکاف‌های موجود در ادبیات را پُر می‌کند، بلکه مسیری نوین برای پژوهش‌های آتی در تقاطع یادگیری عمیق، مالی رفتاری و تحلیل بازارهای نوظهور ترسیم می‌کند. قابلیت تطبیق این معماری با سایر بازارهای مالی و دارایی‌ها، پتانسیل گسترده‌ای برای تعمیم و توسعه بیشتر فراهم می‌آورد و می‌تواند به‌عنوان الگویی برای ادغام هوش مصنوعی پیشرفته در تصمیم‌گیری‌های مالی استراتژیک محسوب شود.

روش‌شناسی پژوهش

در این پژوهش، با اقتباس از مدل پایه گیرتسما و لو (۲۰۲۳) به بررسی عوامل مؤثر بر قیمت گذاری نسبی سهام در عرضه‌های اولیه می‌پردازیم. مطالعه با استفاده از داده‌های 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 داده‌ها و صحت نتایج، شرکت‌های مورد مطالعه بر اساس معیارهای دقیق زیر انتخاب شده‌اند:

- معیار زمان عرضهٔ اولیه. عرضهٔ اولیه در بازه زمانی: شرکت حتماً باید عرضهٔ اولیهٔ سهام خود را در فاصلهٔ زمانی ۱۳۹۲/۰۱/۰۱ تا ۱۴۰۲/۱۲/۲۹انجام داده باشد. این بازه زمانی ده‌ساله، امکان بررسی تأثیر عوامل کلان اقتصادی و پویایی‌های بازار سهام را فراهم می‌آورد.
- معیار نوع شرکت و محل پذیرش. پذیرش در بازار مربوطه: شرکت‌های مورد مطالعه باید در طول دورهٔ پژوهش در بورس اوراق بهادار تهران یا بازار اول و دوم فرابورس ایران پذیرفته شده و فعال باشند.
- معیار دسترسی و کامل بودن داده‌ها: داده‌های مالی و عملیاتی شرکت برای محاسبه کلیه متغیرهای وابسته

(v2s ،v2a ،m2b) و متغیرهای مستقل و کنترلی (استخراج شده از تئوری‌های مالی) باید به‌صورت کامل و بدون وقفه قابل توجه در دسترس باشد.

- حذف شرکت‌های خاص: شرکت‌هایی که در طول دوره مالی به‌دلیل عوامل غیرعادی (مانند ورشکستگی، تعلیق طولانی‌مدت، 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) به‌عنوان 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. کلیهٔ متغیرهای مستقل و کنترلی بر اساس تئوری‌های مالی و مطالعات پیشین استخراج شده و تعریف عملیاتی و نحوهٔ 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 دترانسفورماتور تقویت‌کننده گرادیان عمیق[1] استفاده می‌شود. این معماری ترکیبی از الگوریتم‌های تقویت گرادیان عمیق با سازوکارهای توجه[2] 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 ـ حافظهٔ کوتاه‌مدت طولانی[3]

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

$$h_t = \sum_{i=1}^{M} T_i(x_t) + LSTM_{(x_{t-k:t})}$$ رابطهٔ 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 لایهٔ بعدی منتقل می‌شود.

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

۲. تقویت خودتوجهی[1]

این سازوکار با الهام از ساختارهای خودتوجهی در ترانسفورمرها، ارتباطات بین متغیرهای مختلف را وزن‌دهی و روابط غیرخطی پیچیده را شناسایی می‌کند:

رابطهٔ ۲)

$$A_{ij} = \frac{\exp\left(Q_i \cdot \frac{}{\sqrt{d}}\right)}{\sum_{i=1}^{n} \exp\left(Q_i \cdot \frac{K_l}{\sqrt{d}}\right)}$$

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

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

که در آن، Q، K و V به‌ترتیب ماتریس‌های پرس‌وجو، کلید و مقدار هستند که از h_t محاسبه می‌شوند؛ A وزن توجه بین ویژگی i و ویژگی j؛ d بُعد کلیدها؛ Z خروجی سازوکار خودتوجهی و f_{boost} یک تابع تقویت‌کننده که خروجی خودتوجهی را با ورودی ترکیب می‌کند.

۳. تبدیل پویای ویژگی[2]

این ماژول، ویژگی‌های ورودی را بر اساس الگوهای شناسایی شده در داده‌ها به‌صورت پویا متحول می‌کند:

رابطهٔ ۳)

$$\phi_i = \sigma\left(W_\phi \cdot SAB(h_t)_i + b_\phi\right)$$

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

که در آن، σ تابع فعال‌سازی (مانند سیگموئید)؛ W_ϕ و b_ϕ پارامترهای قابل آموزش؛ ⊙ ضرب عنصر به عنصر؛ ϕ ماتریس دروازه‌ای که مشخص می‌کند کدام ویژگی‌ها باید حفظ شوند و ψ یک تبدیل غیرخطی برای تولید ویژگی‌های جدید است.

٤. جست‌وجوی معماری شبکهٔ عصبی مبتنی بر گرادیان[3]

این بخش به‌صورت خودکار بهترین معماری شبکهٔ عصبی را برای مدل‌سازی نهایی جست‌وجو می‌کند:

رابطهٔ ۴)

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

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

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

$$w^*(\alpha) = argmin_w L_{train}(w, \alpha)$$

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

که در آن، α پارامترهای معماری شبکه؛ w وزن‌های شبکه؛ L_{train} و Lva_l بـه ترتیـب توابـع زیـان روی مجموعـه آموزش و اعتبارسنجی؛ p(α) احتمال انتخاب معماری α و β پارامتر دما است. در نهایت در این پژوهش مـدل‌های مـورد استفاده به شرح زیر است.

مدل ۱)

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

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

مدل ۲)

$$MB\ and\ EVA\ and\ EVS_{it} = \alpha + f\left(\beta_1 WACC_{it} + \beta_2 ROA_{it} + \beta_3 Leverage_{it} + \beta_4 PM_{it} + \beta_5 EPS_{it} + \beta_6 Size_{it} + \beta_7 Firm\ Age_{it} + \beta_8 \frac{CF}{TA_{it}} + \beta_9 Inf_{it} + \beta_{10} FX\ Shock_{it} + \beta_{11} nction\ Index_{it}\right)$$

۵. گردش کار بین لایه‌های مدل

فرایند پردازش داده‌ها در معماری ترانسفورمر تقویت گرادیان عمیق شامل چهار مرحله متوالی اسـت. در مرحلـهٔ نخسـت، داده‌های ورودی که شامل متغیرهای مالی و حسابداری شرکت‌های عرضه اولیه می‌باشد، وارد لایه درخت‌های رگرسـیون افزایشی چندگانه ـ حافظه کوتاه‌مدت طولانی می‌شوند. این لایه بـا ترکیـب قـدرت الگوریتم‌هـای درختـی و شـبکه‌های عصبی بازگشتی، روابط زمانی و روندهای موجود در داده‌های مالی را استخراج می‌کند. خروجـی ایـن لایـه بـه سـازوکار تقویت خودتوجهی منتقل می‌شود که با الهام از ساختارهای توجه در ترانسفورمرها، اهمیت نسبی متغیرها را ارزیابی کـرده و روابط پیچیده بین آن‌ها را شناسایی می‌کند. سپس ماژول تبدیل پویای ویژگی، با استفاده از اطلاعـات اسـتخراج شـده، ویژگی‌های جدیدی ایجاد می‌کند کـه قـدرت تمـایز بیشـتری بـرای مـدل فـراهم می‌آورنـد. در مرحلـهٔ نهـایی، بخـش جست‌وجوی معماری شبکهٔ عصبی مبتنی بر گرادیان، به‌صورت هوشمند و خودکار بهترین سـاختار شـبکه را بـرای تولیـد 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 ماننـد L۱ و L۲، از بیش‌برازش مدل جلوگیری می‌شود. کل ایـن فراینـد به‌صـورت تکـراری انجـام می‌شـود و در هـر تکـرار،

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 عرضهٔ اولیهٔ سهام را فراهم می‌آورد. که گردش کار در بین لایه‌های مدل شرح شکل ۱ به‌صورت زیر است.

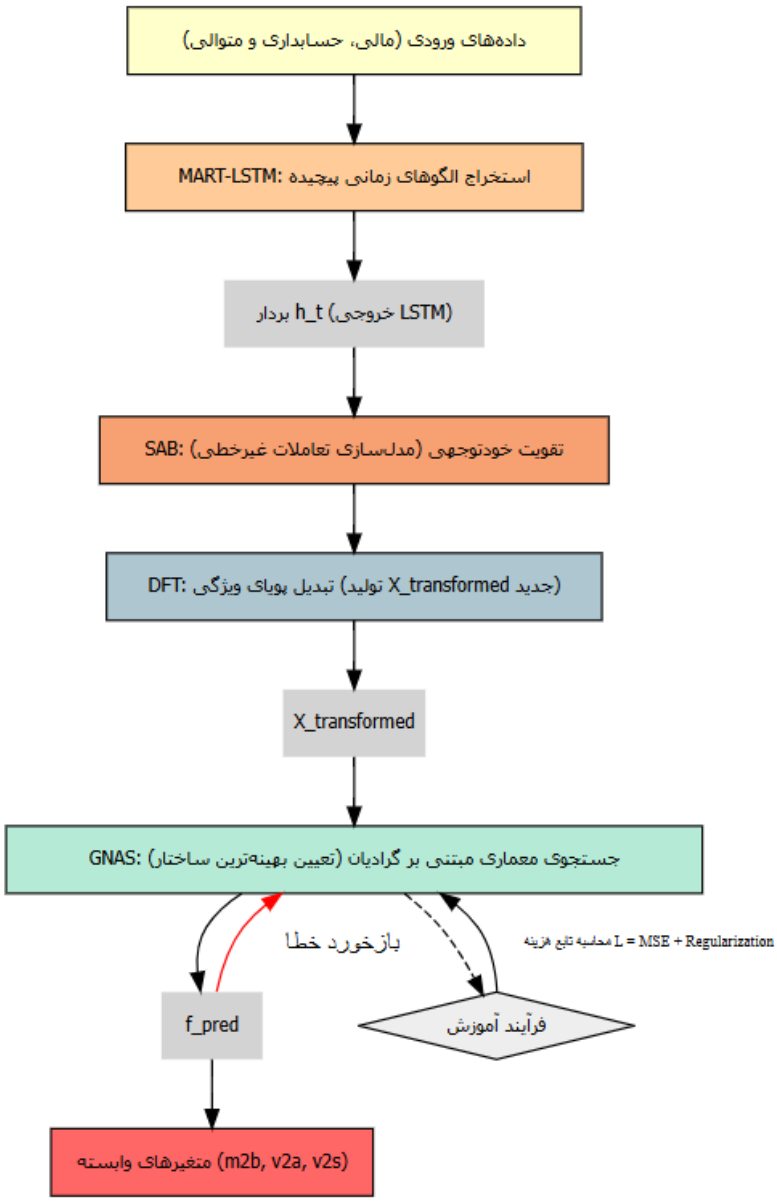

شکل ۱. گردش کار بین لایه‌های مدل

در نهایت با توجه به رابطهٔ نهایی بالا، تعریف مفهومی و نحوهٔ 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	$= (\frac{Equity\ Value_i}{Book\ Equity_{Peers}}) \times Book\ Equity_i$	$(\frac{MV}{BE_{Peer}})$: 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 پیش‌بینی‌شده 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	$= (\frac{Enterprise\ Value}{Assets_{Peers}}) \times Assets_i$	$(\frac{Enterprise\ Value}{Assets_{Peers}})$: میانگین نسبت EV به دارایی شرکت‌های بورسی هم‌صنعت و ماه. $Assets_i$: کل دارایی شرکت i. ابتدا EV را برای شرکت‌های بورسی به‌صورت $EV = MarketCap + TotalDebt - Cash$ 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	$= (\frac{Enterprise\ Value}{Sales_{Peers}}) \times Sales_i$	$(\frac{Enterprise\ Value}{Sales_{Peers}})$: 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	$WACC_{i,t} = (\frac{E}{V} \times Re) + (\frac{D}{V} \times Rd) \times (1 - T_c)$	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؛ سنجه 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 درج‌شده در ترازنامه).
اهرم مالی (Leverage)	درجه اتکای 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)

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

منابع: (گوپتا و کومار، ۲۰۲۳؛ طاهری هفت آسیابی و نادری، ۱۴۰۳؛ گیرتسما 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 نشان‌دهندهٔ 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 به‌سمت 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 به‌سمت مقادیر بالاتر را نشان می‌دهد. سایر متغیرهای مستقل اصلی

دارای کج‌شدگی مثبت هستند. در بخش متغیرهای کنترلی، سن شرکت دارای بزرگ‌ترین انحراف از میانگین است که گستردگی بالای نمونه را از نظر قدمت شرکت‌ها نشان می‌دهد. کج‌شدگی و نوسان‌های بالا در متغیرهای کلان اضافه‌شده، مانند شوک نرخ ارز، بر ساختار نامتقارن ریسک‌های اقتصاد کلان در طول دوره زمانی مطالعه تأکید می‌کند. این یافته‌ها نشان می‌دهند که مدل حاضر برای دستیابی به عملکرد برتر، مجبور به مدیریت و تعدیل این عدم تقارن‌های قوی در داده‌های مالی و کلان است. در مجموع، تحلیل آمار توصیفی نشان می‌دهد که داده‌های پژوهش دارای ناهمگنی و عدم تقارن هستند که این امر استفاده از روش‌های نرمال‌سازی و تکنیک‌های پیشرفته مانند ماشین تقویت گرادیان را برای دستیابی به نتایج دقیق‌تر ضروری می‌سازد.

جدول۳. معیارهای ارزیابی عملکرد مدل‌های مختلف برای پیش‌بینی 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 DGBT پیشنهادی	۰/۲۴۷	۰/۴۹۷	۰/۳۸۵	۰/۸۵۳

منبع: محاسبات پژوهش

نتایج جدول ۳ نشان می‌دهد که الگوریتم پیشنهادی تقویت گرادیان بر پایه ترانسفورمر (دی‌جی‌بی‌تی) با کسب ضریب تعیین برابر ۰/۸۵۳ و ریشهٔ میانگین مربع خطا برابر ۰/۴۹۷، عملکردی به مراتب بهتر از تمامی مدل‌های رقیب داشته است. در مقایسه با رگرسیون خطی چندگانه که ضعیف‌ترین کارایی را با ضریب تعیین ۰/۵۳۴ ثبت کرده است، مدل پیشنهادی توانسته است دقت پیش‌بینی را بیش از ۶۰ درصد افزایش دهد. هرچند مدل‌های مبتنی بر تقویت گرادیان مانند XGBoost و LightGBM عملکرد قابل قبولی از خود نشان داده‌اند؛ اما همچنان از مدل ترکیبی پیشنهادی عقب مانده‌اند. عملکرد ضعیف‌تر مدل حافظهٔ بلند ـ کوتاه‌مدت نیز نشان‌دهندهٔ پیچیدگی بالای داده‌ها و لزوم به‌کارگیری ساختارهای ترکیبی و پیشرفته‌تر برای تحلیل روابط غیرخطی در این محیط است. همچنین، میانگین قدرمطلق خطا برابر ۰/۳۸۵، کیفیت و صحت پیش‌بینی مدل را تأیید می‌کند.

جدول٤. معیارهای ارزیابی عملکرد مدل‌های مختلف برای پیش‌بینیV2A

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
مدل DGBT پیشنهادی	۰/۰۴۷	۰/۲۱۷	۰/۱۷۸	۰/۸۶۵

منبع: محاسبات پژوهش

در پیش‌بینی متغیر نسبت ارزش کل شرکت به ارزش دارایی نیز، الگوریتم پیشنهادی تقویت گرادیان 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. مقایسهٔ 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 تقویت گرادیان 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 ریشهٔ میانگین مربع خطا و میانگین قدرمطلق خطا برای مدل پیشنهادی در کمترین سطح ممکن قرار دارند که قابلیت بالای آن را در حوزهٔ 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 DGBT پیشنهادی	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 تقویت گرادیان 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، نشان‌دهندهٔ بهبودی حدود ۶۷ درصدی در دقت پیش‌بینی است. در مجموع، مشاهده می‌شود که مدل پیشنهادی در پیش‌بینی هر سه متغیر وابسته، نه‌تنها دقت بسیار بالایی دارد، بلکه عملکردی یکپارچه و پایدار را در میان متغیرهای قیمت‌گذاری مختلف به نمایش می‌گذارد.

نتایج تحلیل اهمیت متغیرها در الگوریتم تقویت گرادیان 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، به‌عنوان مهم‌ترین عامل تأثیرگذار شناخته می‌شود که از نظر تئوری نشان‌دهندهٔ کارایی مدیریت در استفاده از دارایی‌ها است. حاشیهٔ 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 ارزش‌گذاری را برجسته می‌سازند. با این حال، الگوهای اهمیت برای هر متغیر وابسته متفاوت است؛ برای مثال، حاشیهٔ سود در پیش‌بینی نسبت ارزش کل شرکت به فروش بیشترین اهمیت را دارد، در حالی که نسبت جریان نقدی به کل دارایی‌ها برای نسبت ارزش کل شرکت به ارزش دارایی مهم‌ترین متغیر محسوب می‌شود.

جدول ٦. اهمیت متغیرها در مدل DGBT برای پیش‌بینی سه متغیر وابسته

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

منبع: محاسبات پژوهش

جالب توجه آن است که نرخ تورم که یک متغیر کلان است، در تمامی مدل‌ها رتبهٔ دوم را به خود اختصاص داده است که نشان‌دهندهٔ تأثیر بسیار قوی و سیستماتیک ریسک‌های کلان بر ارزش‌گذاری شرکت‌ها در بازار سرمایهٔ ایران است. متغیرهایی مانند میانگین موزون هزینه سرمایه و اهرم مالی اهمیت متوسطی دارند که نشان‌دهندهٔ 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 نشان‌دهندهٔ تمرکز بازار ایران بر عوامل عملکردی و سودآوری فوری در مقابل ویژگی‌های تاریخی و ساختاری شرکت‌ها باشد. این تنوع و عدم یکنواختی در اهمیت متغیرها، لزوم استفاده از مدل‌های پیشرفته و ترکیبی مانند DGBT را برای شناسایی و مدل‌سازی این الگوهای پیچیده تأیید می‌کند.

جدول۷. آزمون بک‌تست مدل DGBT با استفاده از داده‌های 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 ۱درصد

نتایج آزمون بک‌تست اعتبار و پایداری مدل DGBT را در دوره‌های زمانی مختلف تأیید می‌کند. در دورهٔ ۱۳۹۲ تا ۱۳۹۵ با ۳۷ شرکت، مدل R^2 برابر ۰/۸۳۱ کسب کرده که نشان‌دهندهٔ عملکرد مناسب حتی با حجم داده کمتر است. روند صعودی ضرایب تعیین از ۰/۸۳۱ به ۰/۸۷۵ در دوره‌های بعدی، نشان‌دهندهٔ بهبود مستمر عملکرد مدل با افزایش حجم داده‌هاست که یکی از ویژگی‌های مطلوب مدل‌های یادگیری ماشین محسوب می‌شود. دورهٔ ۱۳۹۹ تا ۱۴۰۲ با ۷۴ شرکت و R^2 برابر ۰/۸۷۵، بالاترین عملکرد را نشان داده که احتمالاً به‌دلیل تنوع بیشتر داده‌ها و شرایط مختلف بازار است. معناداری آمارهٔ 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 نه‌تنها 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 (M2B، V2A، V2S) نیز نشان‌دهندهٔ قدرت مدل در پیش‌بینی انواع مختلف بازده سهام است.

جدول ۸. مقایسه زمان آموزش و پیش‌بینی مدل‌های مختلف

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

مقایسهٔ عملکرد مدل DGBT در بازارهای بورس و فرابورس نتایج جالبی ارائه می‌دهد. بازار بورس با ۴۲ شرکت و R^2 برابر ۰/۸۶۸ برای M2B، اندکی عملکرد بهتری نسبت به بازار فرابورس با ۱۲۱ شرکت و R^2 برابر ۰/۸۴۳ نشان داده است. این تفاوت احتمالاً به‌دلیل شفافیت بیشتر، استانداردهای گزارش‌دهی بالاتر و کیفیت بهتر اطلاعات در شرکت‌های بورسی است. با این حال، تفاوت تنها ۲/۵درصدی است که نشان می‌دهد مدل برای هر دو بازار کارایی مناسب و قابل اعتمادی دارد. مقادیر MSE و RMSE نیز الگوی مشابهی را نشان می‌دهند. نکتهٔ مهم دیگر اینکه تعداد شرکت‌های فرابورسی (۱۲۱) تقریباً سه برابر شرکت‌های بورسی (۴۲) است؛ اما عملکرد مدل در هر دو گروه قابل قبول باقی مانده که نشان‌دهندهٔ قدرت تعمیم‌پذیری مناسب مدل است. این یافته از نظر عملی اهمیت زیادی دارد زیرا نشان می‌دهد که مدل DGBT قابلیت استفاده در کل طیف بازار سرمایهٔ ایران را دارد و نه‌تنها محدود به شرکت‌های بزرگ و شناخته‌شده بورسی نیست. تفاوت جزئی در عملکرد نشان می‌دهد که مدل توانسته ویژگی‌های 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 لایه‌های 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 درخت‌ها	۱۵۰	۵۰–۳۰۰	۰/۸۵۳	۰/۴۹۷
عمق درخت‌ها	۶	۳–۱۰	۰/۸۵۳	۰/۴۹۷
اندازه دسته	۳۲	۸–۶۴	۰/۸۵۳	۰/۴۹۷
ضریب تنظیم L۱	۰/۰۱	۰/۰۰۱–۰/۱	۰/۸۵۳	۰/۴۹۷
ضریب تنظیم L۲	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 می‌دهد که مدل با تنظیمات بهینه‌شده، عملکرد پایدار و قابل اعتمادی دارد. مقدار بهینه سه لایه خودتوجهی که از محدوده ۱ تا ۵ انتخاب شده، نشان می‌دهد که مدل نیاز به پیچیدگی متوسطی برای عملکرد بهینه دارد و از overfitting جلوگیری شده است. اندازهٔ بعد کلیدهای ۶۴ نیز از محدوده ۱۶ تا ۱۲۸ انتخاب شده که تعادل مناسبی بین قدرت مدل‌سازی و کارایی محاسباتی ایجاد کرده است. پارامترهای مربوط

به بخش درختی مدل شامل ۱۵۰ درخت با عمق ۶ نیز بهینه‌سازی شده‌اند که نشان‌دهندهٔ تعادل مناسب بین دقت و جلوگیری از overfitting است. ضرایب تنظیم L1 و L2 نیز به‌گونه‌ای 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 نشان‌دهندهٔ کیفیت فرایند بهینه‌سازی و مقاومت مدل در برابر تغییرات جزئی است.

جدول ۱۱. عملکرد مدل DGBT به تفکیک صنایع

صنعت	تعداد	R² (M2B)	R² (V2A)	R² (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 به‌دلیل 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 به‌دلیل حساسیت بالا به تغییرات نرخ بهره، سیاست‌های پولی و عوامل کلان اقتصادی باشد. صنایع سنتی مانند سیمان، آهک و گچ (R^2 = ۰/۸۵۱) و فلزات اساسی (R^2 = ۰/۸۶۴) عملکرد متوسط، اما قابل قبولی داشته‌اند که نشان‌دهندهٔ 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 منحصربه‌فرد هر صنعت را تشخیص دهد و بر اساس آن پیش‌بینی‌های متفاوتی ارائه کند که نشان‌دهندهٔ انعطاف‌پذیری و هوش مصنوعی مدل است.

جدول ۱۲. عملکرد مدل DGBT براساس ویژگی‌های شرکت‌ها

ویژگی شرکت	تعداد	R² (M2B)	R² (V2A)	R² (V2S)
شرکت‌های با اندازه بزرگ (Q۴)	۴۱	۰/۸۶۸	۰/۸۸۲	۰/۸۶۱
شرکت‌های با اندازه متوسط (Q۲ – Q۳)	۸۱	۰/۸۵۵	۰/۸۶۷	۰/۸۴۸
شرکت‌های با اندازه کوچک (Q۱)	۴۱	۰/۸۳۷	۰/۸۴۶	۰/۸۲۹
شرکت‌های با سن بالا (بیش از ۲۰ سال)	۴۸	۰/۸۴۵	۰/۸۵۳	۰/۸۳۷
شرکت‌های با سن متوسط (۱۰–۲۰ سال)	۷۲	۰/۸۵۸	۰/۸۷۰	۰/۸۵۱
شرکت‌های با سن پایین (کمتر از ۱۰سال)	۴۳	۰/۸۶۳	۰/۸۷۵	۰/۸۵۶
شرکت‌های با اهرم بالا (Q۴)	۴۱	۰/۸۳۵	۰/۸۴۸	۰/۸۲۷
شرکت‌های با اهرم متوسط (Q۲ – Q۳)	۸۱	۰/۸۵۶	۰/۸۶۹	۰/۸۴۹
شرکت‌های با اهرم پایین(Q۱)	۴۱	۰/۸۷۸	۰/۸۸۷	۰/۸۷۲
شرکت‌های با سودآوری بالاQ) ۴)	۴۱	۰/۸۸۵	۰/۸۹۷	۰/۸۷۹
شرکت‌های با سودآوری متوسط (Q۲ – Q۳)	۸۱	۰/۸۶۲	۰/۸۷۳	۰/۸۵۴
شرکت‌های با سودآوری پایین (Q۱)	۴۱	۰/۸۲۳	۰/۸۳۵	۰/۸۱۵

توضیحات: Q۱، Q۲-Q۳و Q۴ به ترتیب چارک اول، چارک‌های دوم و سوم و چارک چهارم توزیع متغیر مربوطه هستند.

منبع: محاسبات پژوهش

تحلیل عملکرد مدل براساس ویژگی‌های مختلف شرکت‌ها بینش‌های مهمی درباره عوامل مؤثر بر قابلیت پیش‌بینی ارائه می‌دهد. شرکت‌های با اهرم مالی پایین (Q۱) با $R^۲$ برابر ۰/۸۷۸ بهترین قابلیت پیش‌بینی را داشته‌اند که از نظر تئوریک منطقی است؛ زیرا ساختار مالی محافظه‌کارانه‌تر منجر به کاهش ریسک و افزایش قابلیت پیش‌بینی عملکرد می‌شود. شرکت‌های با سودآوری بالا (Q۴) با $R^۲$ برابر ۰/۸۸۵ عملکرد فوق‌العاده‌ای نشان داده‌اند که نشان‌دهندهٔ این است که شرکت‌هایی با عملکرد مالی قوی، الگوهای منظم‌تر و قابل پیش‌بینی‌تری دارند. اندازهٔ شرکت نیز تأثیر مثبتی بر قابلیت پیش‌بینی داشته است و شرکت‌های بزرگ (Q۴) با $R^۲$ برابر ۰/۸۶۸ بهتر از شرکت‌های کوچک ($R^۲$ = ۰/۸۳۷) عمل کرده‌اند. این یافته می‌تواند به‌دلیل ثبات بیشتر، تنوع فعالیت‌ها و شفافیت اطلاعاتی بالاتر در شرکت‌های بزرگ باشد. جالب اینکه سن شرکت الگوی غیرمنتظره‌ای نشان داده است و شرکت‌های جوان(کمتر از ۱۰ سال) با $R^۲$ برابر ۰/۸۶۳ عملکرد بهتری نسبت به شرکت‌های قدیمی (بیشتر از ۲۰ سال) با $R^۲$ برابر ۰/۸۴۵ داشته‌اند. این ممکن است نشان‌دهندهٔ چابکی و انطباق‌پذیری بهتر شرکت‌های جوان با شرایط متغیر بازار باشد.

جدول۱۳. نتایج آزمون‌های قابلیت اطمینان مدل

آزمون	M2B	V2A	V2S
آزمون تقسیم تصادفی داده‌ها (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 بوت‌استرپ (۱۰۰۰ نمونه)	۰/۸۵۳±۰/۰۱۴	۰/۸۶۵±۰/۰۱۲	۰/۸۴۶±۰/۰۱۵
آزمون حذف مشاهده‌های پرت (۵درصد)	۰/۸۶۲±۰/۰۱۲	۰/۸۷۳±۰/۰۱۰	۰/۸۵۵±۰/۰۱۳
آزمون مقاومت به نویز (۱۰درصد نویز)	۰/۸۲۷±۰/۰۲۲	۰/۸۳۸±۰/۰۲۰	۰/۸۲۱±۰/۰۲۴

توضیحات: مقادیر به‌صورت میانگین ± انحراف معیار گزارش شده‌اند.

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 = ۵ و K = ۱۰ 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؛ به‌گونه‌ای 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 نشان‌دهندهٔ مقاومت چشمگیر مدل در برابر اختلال‌های خارجی است. انحراف معیارهای پایین در تمامی آزمون‌ها (بین ۰/۰۱ تا ۰/۰۲۵) نیز تأییدکنندهٔ ثبات و قابلیت اطمینان بالای مدل در شرایط مختلف است.

جدول ۱۴. پردازش زمانی بین مراحل مختلف مدل DGBT

مرحله پردازش	زمان (میلی‌ثانیه)	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 شبکهٔ 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 دربارهٔ معماری و کارایی آن ارائه می‌دهد. لایهٔ درخت‌های رگرسیون LSTM با ۲/۲۵ میلی‌ثانیه و ۴۳/۳ درصد از کل زمان، بیشترین سهم را داشته که نشان‌دهندهٔ 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 وظیفهٔ 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 شبکهٔ عصبی مبتنی بر گرادیان با ۱۲ درصد سهم کمترین زمان را می‌گیرد که نشان‌دهندهٔ بهینه‌سازی مؤثر این بخش است. توزیع نسبتاً متعادل زمان بین اجزای مختلف (هیچ بخشی بیش از ۵۰ درصد زمان را نمی‌گیرد) نشان‌دهندهٔ طراحی بهینه و متعادل مدل است که از bottleneckهای محاسباتی جلوگیری کرده است.

جدول ۱۵. مقایسه اثربخشی روش‌های منظم‌سازی

روش منظم‌سازی	R² (M2B)	R² (V2A)	R² (V2S)	RMSE
بدون منظم‌سازی	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 = ۰/۲)	۰/۸۴۸	۰/۸۶۰	۰/۸۴۱	۰/۵۰۲
روش پیشنهادی (ترکیبی)	۰/۸۵۳	۰/۸۶۵	۰/۸۴۶	۰/۴۹۷

منبع: محاسبات پژوهش

مقایسهٔ روش‌های مختلف منظم‌سازی اهمیت استراتژی ترکیبی در مدل DGBT را نشان می‌دهد. حالت بدون منظم‌سازی با R^2 برابر ۰/۸۲۵ نشان می‌دهد 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 نشان‌دهندهٔ اثربخشی آن در انتخاب ویژگی‌های مهم است. تنظیم L۲ با R^2 برابر ۰/۸۴۶ عملکرد کمی بهتری داشته که به‌دلیل 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 تنظیم‌های L۱ و L۲ بوده است. Early stopping که با صبر ۲۰ epoch اعمال شده، R^2 برابر ۰/۸۴۹ کسب کرده که نشان‌دهندهٔ اثربخشی آن در جلوگیری از overtraining است. ترکیب تمامی روش‌ها (L1+L2+Dropout+Early stopping) که در مدل نهایی استفاده شده، بیشترین عملکرد را با R^2 برابر ۰/۸۵۳ به‌دست آورده است. این نتیجه نشان می‌دهد که استفادهٔ هم‌زمان از چندین تکنیک منظم‌سازی، بر یکدیگر تأثیرهای تکمیلی گذاشته‌اند و به بهینه‌سازی کلی مدل منجر شده‌اند. همچنین مقادیر انحراف معیار پایین (۰/۰۱۲ — ۰/۰۱۹) در تمامی حالات نشان‌دهندهٔ ثبات روش‌های مختلف است؛ اما ترکیب همه روش‌ها کمترین انحراف (۰/۰۱۲) را داشته که تأییدکننده پایداری بالای مدل نهایی است.

جدول ۱۶. پارامترهای بهینه‌شده مدل DGBT (پاسخ به Hyperparameter)

پارامتر	مقدار بهینه	توضیحات
میزان یادگیری	۰/۰۰۱	کنترل اندازه گام در بهینه‌سازی (پاسخ به learning rate)
تعداد درخت‌ها	۱۵۰	تعداد تخمینگرهای Gradient Bossting (پاسخ به n_estimators)
طول گام زمانی LSTM	۴	تعداد دوره‌های زمانی مالی ورودی به حافظه
تعداد لایه‌های خودتوجهی	۳	عمق سازوکار Self-Attention
ضریب تنظیم (رگرسیون) L۱	۰/۰۱	منظم‌سازی برای حفظ سادگی مدل
ضریب تنظیم (رگرسیون) L۲	۰/۰۵	منظم‌سازی برای جلوگیری از Overfitting

منبع: محاسبات پژوهش

جدول ۱۶ پارامترهای بهینه‌شده الگوریتم پیشنهادی تقویت گرادیان بر پایه ترانسفورمر (DGBT) را ارائه می‌دهد که نشان‌دهندهٔ جزئیات فنی دقیق مورد نیاز مدل است. میزان یادگیری بهینه ۰/۰۰۱ و تعداد درخت‌ها (تخمینگرهای

تقویت گرادیان) ۱۵۰ تنظیم شده‌اند که نشان‌دهندهٔ یک فرایند یادگیری آرام و کنترل‌شده برای جلوگیری از بیش‌برازش است. همچنین، پارامترهای مربوط به معماری ترکیبی شامل طول گام زمانی حافظهٔ بلند ـ کوتاه‌مدت (۴ دورهٔ زمانی) و تعداد لایه‌های خودتوجهی (۳ لایه) به‌طور بهینه انتخاب شده‌اند. از سوی دیگر، ضریب تنظیم L۱ (۰/۰۱) و ضریب تنظیم L۲ (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 = ۵)K-fold	۰/۸۵۸±۰/۰۱۵	۰/۸۷۱±۰/۰۱۳	۰/۸۵۱±۰/۰۱۷
آزمون اعتبارسنجی متقابل (K = ۱۰)K-fold	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 دغدغهٔ 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 ±۰/۰۱) 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 ۰/۰۳۸ 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 تبیین کنندگی 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، LightGBM، LSTM 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 ۰/۸۶۵، ۰/۸۸ 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 (LightGBM، LSTM و XGBoost) نیز عملکرد بسیار بهتری نسبت به رگرسیون خطی داشته و در محدودهٔ 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.

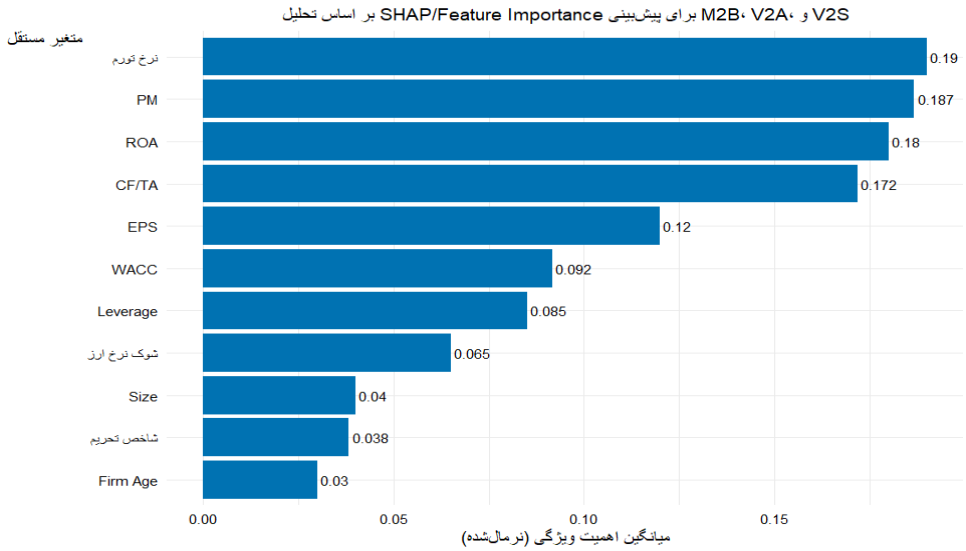

شکل ۲. نمودار میانگین اهمیت ویژگی‌ها در مدل

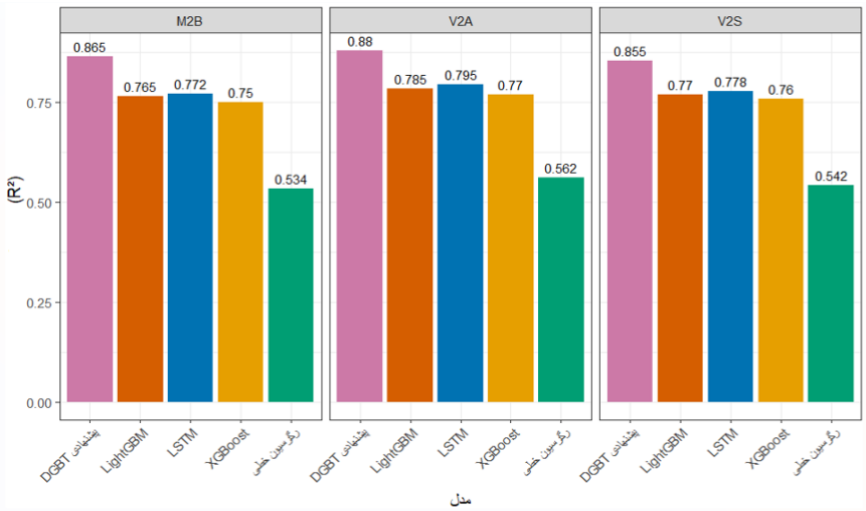

شکل ۳. نمودار مقایسهٔ ضریب تبیین مدل‌های پیش‌بینی

نتیجه‌گیری و پیشنهادها

این پژوهش با هدف توسعه و ارزیابی مدلی مبتنی بر الگوریتم تقویت گرادیان برای پیش‌بینی دقیق بازده عرضهٔ اولیهٔ سهام در بازار سرمایهٔ ایران انجام شده است. انتخاب این هدف به‌دلیل 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 نشان‌دهندهٔ 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 ۰/۸۵۳ و ریشه میانگین مربع خطای ۰/۴۹۷ 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 ۰/۵۳۴ دست یافت که نشان‌دهندهٔ بهبود بیش از ۶۰ درصدی در دقت پیش‌بینی توسط مدل پیشنهادی است. حتی مدل‌های پیشرفته‌تر مانند XGBoost (R^2 = ۰/۷۴۲)، LightGBM (R^2 = ۰/۷۵۴) و LSTM (R^2 = ۰/۷۶۵) نیز قادر نبودند که با مدل DGBT رقابت کنند. میانگین قدرمطلق خطای ۰/۳۸۵ 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 ۰/۸۶۵ و میانگین مربع خطای بسیار پایین ۰/۰۴۷ توانست خطای پیش‌بینی را نسبت به رگرسیون خطی (MSE = ۰/۱۵۲) حدود ۶۹ درصد کاهش دهد. همچنین در پیش‌بینی V2S طبق جدول ۵، مدل پیشنهادی با R^2 = ۰/۸۴۶ و MSE = ۰/۱۴۲ در مقایسه با رگرسیون خطی (R^2 = ۰/۵۴۲؛ MSE = ۰/۴۲۷) 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 سرمایهٔ ایران را فراهم می‌آورد. دقت بالای مدل در پیش‌بینی نسبت‌های مالی کلیدی، نشان‌دهندهٔ 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 ۰/۸۰۶ 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 آن‌ها عملکرد کند. این بهبود عملکرد نه‌تنها ناشی از استفاده از الگوریتم‌های پیشرفته‌تر است، بلکه نشان‌دهندهٔ توانایی مدل در درنظرگیری تعاملات پیچیده بین متغیرها است که در مطالعه روی و همکاران نادیده گرفته شده بود.

در مقایسه با یافته‌های گیرتسما و لو (۲۰۲۳) که بر پتانسیل یادگیری ماشین در ارزش‌گذاری نسبی تأکید داشتند، این مطالعه گام‌های عملی‌تری برداشته است. در حالی که آن‌ها به بررسی قابلیت‌های نظری پرداختند، پژوهش حاضر با ارائهٔ 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 نوآورانه‌تری نسبت به روش‌های سنتی به کار رفته در پژوهش گیرتسما و لو محسوب می‌شود. نتایج ناکاگاوا و یوشیدا (۲۰۲۲) نیز از جنبهٔ دیگری با این پژوهش قابل مقایسه است. آن‌ها کارایی الگوریتم‌های تقویت گرادیان در تحلیل سری‌های زمانی مالی را نشان دادند؛ اما به بررسی داده‌های بازار ژاپن محدود بودند. پژوهش حاضر با گسترش این رویکرد به بازار ایران و در نظرگیری ویژگی‌های خاص این بازار، دامنه کاربرد این تکنیک‌ها را گسترش داده است. علاوه‌براین، استفاده از تکنیک‌های پیشرفته‌تر مانند جست‌وجوی معماری شبکهٔ عصبی، پیشرفت قابل توجهی نسبت به روش‌های استاتیک آن‌ها محسوب می‌شود.

یکی از دستاوردهای مهم این پژوهش، شناسایی روابط پیچیده بین متغیرهای مؤثر بر قیمت‌گذاری عرضه‌های اولیه است که در مطالعات قبلی کمتر مورد توجه قرار گرفته بود. نتایج جدول ۶ نشان می‌دهد که نرخ تورم با میانگین اهمیت ۰/۱۹ در رتبهٔ دوم در تمامی مدل‌های پیش‌بینی قرار دارد که بیانگر تأثیر بسیار قوی و سیستماتیک ریسک‌های کلان بر ارزش‌گذاری شرکت‌ها در بازار سرمایهٔ ایران است. همچنین، بازده دارایی‌ها با اهمیت ۰/۲۱ در پیش‌بینی M2B، حاشیهٔ سود با اهمیت ۰/۲۲۵ در پیش‌بینی V2S و نسبت جریان نقدی به کل دارایی‌ها با اهمیت ۰/۲ در پیش‌بینی V2A، به‌عنوان مهم‌ترین متغیرهای مالی شناسایی شدند. این تنوع در اهمیت متغیرها برای هر متغیر وابسته، نشان‌دهندهٔ پیچیدگی روابط است که به مدل‌های پیشرفته برای شناسایی آن‌ها نیازمند است. شکل ۲ نیز این یافته‌ها را با نمایش بصری میانگین اهمیت ویژگی‌ها بر اساس تحلیل SHAP تأیید می‌کند که در آن نرخ تورم (۰/۱۹)، حاشیهٔ سود (۰/۱۸۷) و بازده دارایی‌ها (۰/۱۸) به‌عنوان سه متغیر اصلی برجسته شده‌اند، در حالی که متغیرهای ساختاری مانند شاخص تحریم (۰/۰۳۸) و عمر شرکت (۰/۰۳) کمترین اهمیت را دارند.

مدل توسعه‌یافته نه‌تنها متغیرهای سنتی مانند WACC، ROA و اهرم مالی را در نظر می‌گیرد، بلکه از طریق سازوکار خودتوجهی، تعاملات غیرخطی بین این متغیرها را نیز مدل‌سازی می‌کند. این رویکرد در مقایسه با مطالعات قبلی نظیر سعیدی اقدم و همکاران (۱۴۰۱) که بر تحلیل ساده متغیرها تأکید داشتند، پیشرفت چشمگیری محسوب می‌شود. تبدیل پویای ویژگی که در این مطالعه معرفی شده است، نسبت به روش‌های استاتیک پیشین مزیت چشمگیری دارد. این سازوکار به مدل امکان تطبیق با شرایط مختلف بازار را می‌دهد، در حالی که مطالعات سابق معمولاً وزن‌های ثابتی برای متغیرها در نظر می‌گرفتند. این قابلیت تطبیقی باعث می‌شود که مدل بتواند در شرایط متغیر بازار، عملکرد مناسبی داشته باشد که نکته‌ای 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 = ۱۰، ضرایب تعیین ۰/۸۶۰ ± ۰/۰۱۳ برای M2B، ۰/۸۷۳ ± ۰/۰۱۱ برای V2A و ۰/۸۵۴ ± ۰/۰۱۴ برای V2S حاصل شده است. انحراف معیار بسیار پایین (حدود ±۰/۰۱) 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 ۰/۰۰۱، تعداد ۱۵۰ درخت، ۴ گام زمانی LSTM و ۳ لایهٔ خودتوجهی است که از طریق فرایند بهینه‌سازی دقیق به‌دست آمده‌اند. ضرایب تنظیم L۱ و L۲ به‌ترتیب ۰/۰۱ و ۰/۰۵ نیز برای جلوگیری از بیش‌برازش و حفظ قابلیت تعمیم‌پذیری مدل تنظیم شده‌اند. این پیکربندی بهینه نشان‌دهندهٔ 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 ۶۰ تا ۶۹ 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 ۵۳/۴ درصد از تغییرات M2B را تبیین کند، مدل DGBT این مقدار را به ۸۵/۳ 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 تقویت گرادیان 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 فاصلهٔ قابل توجهی دارند؛ به‌طوری که تمامی مدل‌های پیشرفته (XGBoost، LightGBM، LSTM و DGBT) در محدودهٔ R^2 بالای ۰/۷۴ قرار دارند؛ در حالی که رگرسیون خطی در محدودهٔ ۰/۵۳ تا ۰/۵۶ باقی مانده

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 شبکهٔ 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 نه‌تنها 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 نه‌تنها 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، به‌تدریج از این تکنیک‌های پیشرفته در تحلیل‌های خود بهره‌برداری کنند. با توجه به برتری قاطع مدلDGBT 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 نشان‌دهندهٔ حساسیت بازار ایران به شرایط اقتصادی است.

توسعهٔ رابط‌های کاربری ساده برای استفادهٔ عملی از این مدل‌ها ضروری است تا فاصلهٔ 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 حوزهٔ تحلیل‌های مالی فراهم آورند. همچنین، با توجه به تفاوت‌های مشاهده شده در اهمیت متغیرها برای پیش‌بینی M2B، V2A 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. علاوه‌براین، 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 حاشیهٔ سود و بازده دارایی‌ها که از طریق تحلیل SHAP در شکل ۲ نمایش داده شده است، می‌تواند به‌عنوان الگویی برای توسعه مدل‌های مشابه در سایر بازارهای نوظهور با ویژگی‌های مشابه مورد استفاده قرار گیرد.

منابع

آقایی، 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، سحنعلی (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*، ۱(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 مینوئی، 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، آزیتا (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 عطاآبادی، 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 چالاکی، پری (۱۴۰۴). ارائهٔ الگوی بهینهٔ 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 مبتنی‌بر 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 رابطهٔ علیت بین عرضه اولیهٔ 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. & Rahnama 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

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

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