


Predicting Corporate Bankruptcy in Listed Companies Using Artificial Intelligence Algorithms and Financial Statement Data

1. Erfan Alem* : Department of Management Accounting, Faculty of Economics and Management, Qom State University, Qom, Iran. Email: erfan1378alem@gmail.com
(Corresponding Author)

Abstract:

This study aimed to predict the bankruptcy risk of firms listed on the stock exchange using machine learning algorithms and financial statement data and to identify the most influential predictors of bankruptcy risk. This applied quantitative study employed a descriptive–analytical design. The statistical population consisted of companies listed on the stock exchange during the 2018–2024 period. Eligible firms were selected through a screening process based on data availability and consistency criteria. Financial data were extracted from audited financial statements, annual reports, and financial databases. Two machine learning algorithms, Random Forest (RF) and Balanced Random Forest (BRF), were used to predict bankruptcy risk. Model performance was evaluated using Area Under the Curve (AUC), Accuracy, Precision, Recall, and F1-score. Feature Importance analysis was conducted to determine the contribution of each predictor, while the Generalized Method of Moments (GMM) was employed to examine dynamic relationships among variables. The results indicated that the Random Forest model achieved an overall accuracy of 0.855 with an AUC of 0.453; however, it showed limited ability to identify bankrupt firms. In contrast, the Balanced Random Forest model demonstrated superior performance in detecting financially distressed companies despite a slightly lower overall accuracy (0.824). The BRF model yielded Precision, Recall, and F1-score values of 0.333, 0.211, and 0.258, respectively. Confusion matrix results further confirmed the greater sensitivity of the balanced model toward the minority class. Feature importance analysis revealed that institutional ownership, accounts turnover ratio, earnings-to-price ratio, and cash-to-sales ratio were among the most influential variables in predicting bankruptcy risk. The findings suggest that machine learning techniques, particularly the Balanced Random Forest algorithm, provide an effective framework for the early identification of firms facing bankruptcy risk. Integrating financial indicators with ownership structure and corporate governance variables can enhance predictive performance and support more informed decision-making by investors, managers, and financial analysts.

Keywords: Bankruptcy Risk, Bankruptcy Prediction, Machine Learning, Balanced Random Forest, Financial Statements, Listed Companies.

Article history



Received: 21 January 2026

Revised: 05 June 2026

Accepted: 13 June 2026

Initial Publish: 17 June 2026

Final Publish: 23 August 2027



Extended Abstract**Introduction**

Corporate bankruptcy remains one of the most critical challenges in capital markets because of its substantial consequences for investors, creditors, managers, regulators, and the broader financial system. The failure of firms not only results in the destruction of shareholder value but may also contribute to financial instability, reduced market confidence, and systemic risk transmission. Traditional financial theory has long emphasized the relationship between risk and return, suggesting that market participants continuously evaluate risk when making investment decisions. However, contemporary research indicates that firm-specific characteristics and financial vulnerabilities often provide stronger signals of impending failure than broad market indicators alone (Abad, 2025; Asimit & Li, 2017; Clements & Liao, 2020).

Financial distress and bankruptcy prediction have therefore become central topics in accounting, finance, and risk management literature. Early identification of financially troubled firms enables investors to make more informed portfolio decisions, allows creditors to manage credit risk more effectively, and provides managers with opportunities to implement corrective actions before financial deterioration becomes irreversible. Previous studies have demonstrated that indicators derived from financial statements, including profitability, liquidity, leverage, and operational efficiency ratios, contain valuable information regarding a firm's future financial health (Hamidi et al., 2024; Jamil, 2023).

Recent developments in financial markets have further highlighted the importance of accurate bankruptcy prediction systems. High-profile corporate failures and financial crises have demonstrated how weaknesses in risk management, governance structures, and financial oversight can escalate into major systemic events. The collapse of Credit Suisse serves as a contemporary example of how unresolved financial vulnerabilities may trigger severe institutional consequences and broader market disruptions (Alshater, 2026). Similarly, research has shown that external shocks such as natural disasters, macroeconomic uncertainty, and environmental disruptions can significantly affect firms' investment behavior and financial stability, thereby increasing bankruptcy risk (Yang et al., 2026).

The growing complexity of financial markets has challenged the effectiveness of traditional statistical bankruptcy prediction models. Conventional approaches such as discriminant analysis, logistic regression, and survival analysis often rely on restrictive assumptions regarding variable distributions and linear relationships. While these models have contributed significantly to bankruptcy research, they may struggle to capture the nonlinear interactions and multidimensional patterns that characterize modern financial datasets. Consequently, researchers have increasingly turned toward artificial intelligence and machine learning techniques to improve predictive performance.

Artificial intelligence offers several advantages for financial forecasting. Machine learning algorithms can process large volumes of structured and unstructured data, identify hidden patterns, and model complex nonlinear relationships without imposing strict statistical assumptions. Research has shown that AI-based systems can improve budgeting efficiency, enhance financial decision-making processes, and provide more accurate predictions than many conventional analytical methods (Kermani & Sadeghi-Manesh, 2024; Sharifi, 2023). These capabilities have encouraged the adoption of machine learning approaches in various financial applications, including stock return forecasting, risk assessment, fraud detection, and bankruptcy prediction.

In the context of capital markets, AI-driven models have demonstrated considerable potential for identifying financial vulnerabilities before they become visible through traditional analysis. Studies conducted in the Iranian capital market have

shown that machine learning algorithms can successfully predict negative stock returns and uncover hidden relationships among financial variables (Dalili et al., 2025). Likewise, qualitative investigations have emphasized the transformative role of machine learning and artificial intelligence in financial and managerial analysis, suggesting that these technologies can significantly improve forecasting quality and strategic decision-making (Asadi et al., 2025).

Beyond financial ratios, several organizational and governance-related factors have been identified as important determinants of bankruptcy risk. Corporate reputation, ownership structure, governance quality, and organizational networks may influence financial resilience and market perceptions. Firms with stronger reputations often experience lower financial risk and greater investor confidence, reducing their vulnerability to financial distress (Khatanlou et al., 2025). Similarly, network-based analyses have demonstrated that organizational interdependencies may contribute to risk transmission across firms and markets, highlighting the importance of structural characteristics in financial stability assessments (Al-Hafi et al., 2025).

The reliability of financial information also plays a critical role in bankruptcy prediction. Financial statements constitute the primary source of information for evaluating firm performance and financial health. However, the usefulness of these reports depends on the quality and transparency of financial reporting practices. Research has shown that creative accounting techniques can distort financial information, reduce transparency, and increase the likelihood of corporate bankruptcy by masking underlying financial weaknesses (Pourghaffar & Eghbal Mazraeh, 2025). Therefore, effective bankruptcy prediction models must not only utilize financial indicators but also account for the quality and reliability of the information being analyzed.

Market information and investor behavior further influence financial risk assessment. News dissemination, investor sentiment, and information flows have been shown to affect stock returns and risk perceptions. Research demonstrates that news analysis can improve systematic risk assessment and provide valuable insights into market behavior (Memarpour et al., 2025). Moreover, investor sentiment significantly affects sectoral returns, while misinformation and fake news may create substantial economic consequences and distort market expectations (Bakir & McStay, 2018; Curatola et al., 2016). These findings underscore the importance of integrating advanced analytical techniques capable of processing complex information environments.

Although prior studies have investigated various dimensions of financial distress, bankruptcy prediction, and artificial intelligence applications, relatively limited research has focused on comparing machine learning algorithms for bankruptcy prediction using financial statement data within the Iranian stock market context. Furthermore, the identification of the most influential financial and structural variables contributing to bankruptcy prediction remains an important research challenge. Accordingly, this study sought to predict bankruptcy risk among listed companies using machine learning algorithms and financial statement information while identifying the variables with the greatest predictive importance.

Methods and Materials

This study employed an applied quantitative research design with a descriptive–analytical approach. The statistical population consisted of companies listed on the stock exchange during the period from 2018 to 2024. Firms were selected using a screening procedure based on data availability, consistency of financial reporting, and continuity of operations throughout the study period. Financial institutions, banks, insurance companies, and financial intermediaries were excluded due to their distinct financial structures and regulatory environments.

The required data were extracted from audited financial statements, annual reports, and official financial databases. Variables included financial ratios, operational indicators, ownership-related measures, and firm-specific characteristics such as company size, age, market share, industrial concentration, and cash flow measures. Bankruptcy risk served as the dependent variable.

Two machine learning algorithms were utilized to predict bankruptcy risk: Random Forest (RF) and Balanced Random Forest (BRF). The Balanced Random Forest algorithm was specifically employed to address the class imbalance problem arising from the relatively small number of bankrupt firms compared with healthy firms. Model performance was evaluated using multiple indicators, including Accuracy, Precision, Recall, F1-score, Receiver Operating Characteristic (ROC) curves, and Area Under the Curve (AUC). Feature importance analysis was conducted to determine the relative contribution of each predictor to bankruptcy classification. In addition, dynamic panel data analysis using the Generalized Method of Moments (GMM) was applied to examine relationships among the study variables and assess the robustness of findings.

Findings

The results revealed notable differences between the two machine learning models. The Random Forest model achieved an overall accuracy of approximately 0.855 and an AUC value of 0.453. Despite its relatively high overall classification accuracy, the model demonstrated poor performance in identifying bankrupt firms. Precision, Recall, and F1-score values were close to zero, indicating a strong tendency toward classifying observations as non-bankrupt firms.

In contrast, the Balanced Random Forest model achieved an overall accuracy of approximately 0.824 and an AUC value of 0.426. Although its overall accuracy was slightly lower, the model demonstrated substantially better performance in identifying firms at risk of bankruptcy. The model produced Precision, Recall, and F1-score values of approximately 0.333, 0.211, and 0.258, respectively, indicating improved sensitivity toward the minority class.

The confusion matrix analysis further confirmed these findings. The Random Forest model correctly identified nearly all non-bankrupt firms but failed to detect bankrupt companies effectively. Conversely, the Balanced Random Forest model successfully identified several bankrupt firms, although some false-positive classifications remained. These results suggest that balancing techniques improved the model's ability to recognize financially distressed firms.

Feature importance analysis identified institutional ownership, accounts turnover ratio, earnings-to-price ratio, and cash-to-sales ratio as the most influential predictors of bankruptcy risk. Additional variables related to firm characteristics and governance structures also contributed meaningfully to model performance. The findings indicate that both financial indicators and governance-related variables play important roles in distinguishing bankrupt firms from healthy companies.

Descriptive analyses demonstrated that bankruptcy risk remained relatively stable throughout the study period, with average risk measures fluctuating within a limited range. Comparisons across firm-size quartiles revealed only minor differences in average bankruptcy risk, suggesting that company size alone was not a decisive determinant of financial distress within the sample.

Discussion and Conclusion

The findings demonstrate that machine learning algorithms provide valuable tools for bankruptcy prediction and financial risk assessment. While the Random Forest model achieved higher overall accuracy, its inability to identify bankrupt firms effectively limits its practical usefulness for early warning purposes. The Balanced Random Forest model, despite slightly

lower overall accuracy, offered superior detection of financially distressed firms and therefore represents a more appropriate approach for bankruptcy prediction in imbalanced financial datasets.

The results highlight the importance of considering class imbalance when developing predictive models for rare financial events. In bankruptcy prediction, identifying distressed firms is often more valuable than maximizing overall classification accuracy. Consequently, evaluation metrics such as Recall and F1-score should receive greater emphasis than accuracy alone when assessing model effectiveness.

The identification of institutional ownership, liquidity-related indicators, valuation measures, and operational efficiency variables as key predictors suggests that bankruptcy risk is shaped by a combination of financial performance and governance characteristics. Firms exhibiting weaknesses in cash generation, operational efficiency, and ownership monitoring appear more vulnerable to financial distress. These findings reinforce the importance of integrating both financial and structural indicators into predictive systems.

The study further demonstrates that artificial intelligence can enhance financial analysis by uncovering complex relationships that may not be detectable through traditional statistical approaches. As financial markets become increasingly complex and data-rich, machine learning methods are likely to play an increasingly important role in risk management, investment analysis, and corporate monitoring.

Overall, the findings indicate that machine learning algorithms, particularly Balanced Random Forest models, offer significant potential for the early identification of bankruptcy risk among listed firms. The integration of financial statement information with governance and ownership variables can improve predictive performance and provide valuable decision-support tools for investors, managers, creditors, and regulatory authorities. The development of more sophisticated AI-driven early warning systems may contribute to improved financial stability, enhanced risk management practices, and more efficient capital market operations in the future.

Authors' Contributions

Authors equally contributed to this article.

Acknowledgments

Authors thank all participants who participate in this study.

Declaration of Interest

The authors report no conflict of interest.

Funding

According to the authors, this article has no financial support.

Ethical Considerations

All procedures performed in this study were under the ethical standards.

پیش‌بینی ورشکستگی شرکت‌های بورسی با استفاده از الگوریتم‌های هوش مصنوعی و داده‌های صورت‌های مالی

تاریخچه مقاله

تاریخ دریافت: ۱ بهمن ۱۴۰۴

تاریخ بازنگری: ۱۵ خرداد ۱۴۰۵

تاریخ پذیرش: ۲۳ خرداد ۱۴۰۵

تاریخ چاپ اولیه: ۲۷ خرداد ۱۴۰۵

تاریخ چاپ نهایی: ۱ شهریور ۱۴۰۶

۱. عرفان عالم* ID: گروه حسابداری مدیریت، دانشکده اقتصاد و مدیریت، دانشگاه دولتی قم، قم، ایران. ایمیل: erfan1378alem@gmail.com (نویسنده مسئول)

چکیده

هدف این پژوهش، پیش‌بینی ریسک ورشکستگی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار با بهره‌گیری از الگوریتم‌های یادگیری ماشین و داده‌های استخراج‌شده از صورت‌های مالی و همچنین شناسایی مهم‌ترین متغیرهای مؤثر بر این پیش‌بینی بود. این پژوهش از نوع کاربردی، کمی و تجربی با رویکرد توصیفی-تحلیلی است. جامعه آماری شامل شرکت‌های

پذیرفته‌شده در بورس اوراق بهادار طی سال‌های ۱۳۹۷ تا ۱۴۰۳ بود که پس از اعمال معیارهای غربالگری، شرکت‌های واجد شرایط انتخاب شدند. داده‌های مورد نیاز از صورت‌های مالی حسابرسی‌شده، گزارش‌های سالانه و پایگاه‌های اطلاعاتی مالی گردآوری شد. برای پیش‌بینی ورشکستگی از دو الگوریتم جنگل تصادفی (RF) و جنگل تصادفی متوازن (BRF) استفاده شد. عملکرد مدل‌ها با شاخص‌های AUC، Accuracy، Precision، Recall و F1 ارزیابی گردید. همچنین به منظور بررسی اهمیت متغیرها از شاخص Feature Importance و برای تحلیل روابط پویای متغیرها از روش گشتاورهای تعمیم‌یافته (GMM) استفاده شد. نتایج نشان داد مدل جنگل تصادفی دارای دقت کلی ۰.۸۵۵ و مقدار AUC برابر با ۰.۴۵۳ بود، اما در شناسایی شرکت‌های ورشکسته عملکرد ضعیفی داشت. در مقابل، مدل جنگل تصادفی متوازن با وجود دقت کلی کمتر (۰.۸۲۴)، توانست عملکرد بهتری در شناسایی شرکت‌های دارای ریسک ورشکستگی ارائه دهد و مقادیر Precision، Recall و F1 آن به ترتیب برابر با ۰.۳۳۳، ۰.۲۱۱ و ۰.۲۵۸ گزارش شد. نتایج ماتریس آشفتگی نیز نشان داد مدل متوازن نسبت به مدل استاندارد حساسیت بیشتری نسبت به طبقه اقلیت دارد. تحلیل اهمیت متغیرها آشکار ساخت که مالکیت نهادی، نسبت گردش حساب‌ها، نسبت قیمت به سود و نسبت وجه نقد به فروش از مهم‌ترین عوامل مؤثر در پیش‌بینی ورشکستگی شرکت‌ها هستند. یافته‌های پژوهش نشان داد الگوریتم‌های یادگیری ماشین، به‌ویژه جنگل تصادفی متوازن، ظرفیت مناسبی برای شناسایی زود هنگام شرکت‌های در معرض ورشکستگی دارند. ترکیب شاخص‌های مالی با متغیرهای ساختار مالکیت و حاکمیت شرکتی می‌تواند دقت مدل‌های پیش‌بینی را افزایش دهد و به سرمایه‌گذاران، مدیران و تحلیلگران مالی در مدیریت ریسک و تصمیم‌گیری آگاهانه‌تر کمک کند.

کلیدواژه‌گان: ریسک ورشکستگی، پیش‌بینی ورشکستگی، یادگیری ماشین، جنگل تصادفی متوازن، صورت‌های مالی، شرکت‌های بورسی.

شبهه استناددهی: عالم، عرفان. (۱۴۰۶). پیش‌بینی ورشکستگی شرکت‌های بورسی با استفاده از الگوریتم‌های هوش مصنوعی و داده‌های صورت‌های مالی. حسابداری، امور مالی و هوش محاسباتی، ۵(۳)، ۲۱-۱.



ورشکستگی شرکت‌ها یکی از مهم‌ترین مخاطرات بازارهای مالی و سرمایه محسوب می‌شود که پیامدهای آن فراتر از محدوده یک بنگاه اقتصادی بوده و می‌تواند ثبات مالی، اعتماد سرمایه‌گذاران و کارایی بازار سرمایه را تحت تأثیر قرار دهد. در ادبیات مالی، ورشکستگی به وضعیتی اطلاق می‌شود که شرکت توانایی ایفای تعهدات مالی خود را از دست داده و در نتیجه با بحران نقدینگی، کاهش سودآوری و افت ارزش بازار مواجه می‌شود. از این رو، شناسایی زودهنگام نشانه‌های در ماندگی مالی و پیش‌بینی احتمال وقوع ورشکستگی از مهم‌ترین دغدغه‌های پژوهشگران، مدیران مالی، سرمایه‌گذاران و سیاست‌گذاران اقتصادی به شمار می‌رود. اهمیت این موضوع به‌ویژه در بازارهای نوظهور که با عدم اطمینان بیشتر، نوسانات اقتصادی شدیدتر و محدودیت‌های اطلاعاتی مواجه هستند، دوچندان است. در چنین شرایطی، توسعه ابزارهای تحلیلی دقیق برای شناسایی شرکت‌های در معرض بحران مالی می‌تواند نقش مؤثری در کاهش ریسک سرمایه‌گذاری و بهبود تخصیص منابع مالی ایفا کند (Hamidi et al., 2024; Jamil, 2023).

یکی از مبانی نظری مهم در تحلیل وضعیت مالی شرکت‌ها، نظریه رابطه ریسک و بازده است که در قالب مدل قیمت‌گذاری دارایی‌های سرمایه‌ای تبیین شده است. بر اساس این دیدگاه، بازده مورد انتظار سرمایه‌گذاران تابعی از میزان ریسک پذیرفته‌شده است و ارزیابی صحیح ریسک نقش اساسی در تصمیم‌گیری‌های مالی دارد. با این حال، مطالعات جدید نشان داده‌اند که اتکای صرف به ریسک سیستماتیک برای ارزیابی وضعیت شرکت‌ها کافی نیست و عوامل خاص شرکت، ساختار مالی، کیفیت گزارشگری و ریسک‌های درون‌سازمانی نیز می‌توانند در شکل‌گیری بحران‌های مالی و ورشکستگی نقش تعیین‌کننده‌ای داشته باشند. از این منظر، تحلیل جامع ریسک مستلزم توجه همزمان به متغیرهای مالی، ساختاری و محیطی است تا بتوان تصویری دقیق‌تر از وضعیت آتی شرکت‌ها ارائه کرد (Abad, 2025; Asimit & Li, 2017; Clements & Liao, 2020).

در دهه‌های گذشته، پیش‌بینی ورشکستگی عمدتاً بر مبنای مدل‌های آماری سنتی انجام می‌شد. این مدل‌ها با استفاده از نسبت‌های مالی، شاخص‌های نقدینگی، سودآوری و ساختار سرمایه تلاش می‌کردند احتمال شکست مالی شرکت‌ها را برآورد کنند. هرچند این رویکردها نقش مهمی در توسعه ادبیات مالی ایفا کرده‌اند، اما محدودیت‌هایی نظیر فرض خطی بودن روابط میان متغیرها، حساسیت به داده‌های پرت و ناتوانی در شناسایی الگوهای پیچیده موجب شده است که کارایی آنها در محیط‌های اقتصادی پیچیده کاهش یابد. از سوی دیگر، افزایش حجم داده‌های مالی و پیچیدگی روابط میان متغیرها نیازمند استفاده از روش‌هایی است که بتوانند تعاملات چندبعدی و غیرخطی را به‌صورت مؤثر تحلیل کنند (Asimit & Li, 2017; Clements & Liao, 2020).

ظهور فناوری‌های هوش مصنوعی و یادگیری ماشین افق‌های جدیدی را در حوزه تحلیل مالی و پیش‌بینی ورشکستگی گشوده است. این فناوری‌ها قادرند با پردازش حجم عظیمی از داده‌ها و شناسایی الگوهای پنهان، دقت پیش‌بینی را نسبت به روش‌های سنتی افزایش دهند. الگوریتم‌های یادگیری ماشین می‌توانند بدون نیاز به فرض‌های محدودکننده آماری، روابط پیچیده میان متغیرها را استخراج کرده و مدل‌هایی با قدرت پیش‌بینی بالا ارائه دهند. پژوهش‌های اخیر نشان داده‌اند که استفاده از هوش مصنوعی در حوزه‌های مختلف مالی، از جمله بودجه‌بندی سرمایه‌ای، ارزیابی عملکرد و تحلیل ریسک، موجب افزایش دقت تصمیم‌گیری و کاهش خطاهای پیش‌بینی می‌شود. در این راستا، کرمانی و صادقی‌منش نشان دادند که الگوریتم‌های هوش مصنوعی می‌توانند کارایی فرایندهای مالی را بهبود بخشند و زمینه تصمیم‌گیری مبتنی بر داده را فراهم سازند. همچنین شریفی بر نقش فناوری‌های محاسباتی در ارتقای کیفیت تصمیمات بودجه‌بندی سرمایه‌ای تأکید کرده است (Kermani & Sadeghi-Manesh, 2024; Sharifi, 2023).

در حوزه بازار سرمایه، کاربرد هوش مصنوعی به‌طور گسترده‌ای مورد توجه قرار گرفته است. دلیلی، آزادی‌هیر و ارچین‌لیسار نشان دادند که الگوریتم‌های هوش مصنوعی قادرند وقوع بازده منفی سهام را با دقت قابل قبولی پیش‌بینی کنند و روابط پنهان میان متغیرهای مالی و عملکرد بازار را شناسایی نمایند. همچنین اسدی، بیطار و قربانیان با توسعه یک مدل کیفی در زمینه یادگیری ماشین و هوش مصنوعی در هزینه‌یابی پروژه‌ها، ظرفیت بالای این فناوری‌ها را برای بهبود تحلیل‌های مالی و مدیریتی نشان دادند. این مطالعات بیانگر آن است که هوش مصنوعی نه‌تنها در تحلیل داده‌های مالی بلکه در شناسایی الگوهای مرتبط با ریسک و بحران نیز از توانمندی بالایی برخوردار است (Asadi et al., 2025; Dalili et al., 2025).

از سوی دیگر، صورت‌های مالی همچنان مهم‌ترین منبع اطلاعاتی برای ارزیابی وضعیت اقتصادی شرکت‌ها محسوب می‌شوند. اطلاعات منعکس‌شده در صورت‌های مالی، تصویری از سودآوری، نقدینگی، ساختار سرمایه، کارایی عملیاتی و توان بازپرداخت بدهی‌های شرکت ارائه می‌دهد. نسبت‌های مالی استخراج‌شده از این صورت‌ها می‌توانند نشانه‌های

اولیه درماندگی مالی را آشکار سازند. با این حال، کیفیت این اطلاعات نقش تعیین کننده‌ای در قابلیت اتکای پیش‌بینی‌ها دارد. در صورتی که شرکت‌ها از رویه‌های حسابداری خلاقانه استفاده کنند، اطلاعات مالی ممکن است تصویر واقعی از وضعیت شرکت را منعکس نکند و در نتیجه ارزیابی ریسک با خطا مواجه شود. پژوهش پورغفار و اقبال مزرعه نشان داد که حسابداری خلاقانه می‌تواند احتمال ورشکستگی شرکت‌ها را افزایش داده و موجب کاهش شفافیت گزارشگری مالی شود. این یافته‌ها اهمیت کیفیت اطلاعات مالی در توسعه مدل‌های پیش‌بینی ورشکستگی را برجسته می‌سازد (Pourghaffar & Eghbal Mazraeh, 2025).

علاوه بر شاخص‌های مالی، ویژگی‌های ساختاری شرکت‌ها نیز در شکل‌گیری ریسک ورشکستگی نقش مهمی ایفا می‌کنند. یکی از این عوامل، شهرت شرکت است که به‌عنوان یک دارایی نامشهود می‌تواند بر ادراک سرمایه‌گذاران و اعتماد بازار تأثیرگذار باشد. شرکت‌هایی که از شهرت و اعتبار بیشتری برخوردارند معمولاً دسترسی آسان‌تری به منابع مالی دارند و در شرایط بحرانی از حمایت بیشتری برخوردار می‌شوند. در این زمینه، ختن‌لو، سویزی و کاظمی علوم نشان دادند که شهرت شرکت با کاهش ریسک ورشکستگی و افزایش بازده سهام رابطه معناداری دارد. این نتایج بیانگر آن است که عوامل غیرمالی نیز می‌توانند در ارزیابی احتمال شکست مالی شرکت‌ها مورد توجه قرار گیرند (Khatanlou et al., 2025).

در سال‌های اخیر، توجه پژوهشگران به نقش ساختارهای شبکه‌ای و وابستگی‌های میان بنگاه‌ها نیز افزایش یافته است. در بازارهای مالی مدرن، شرکت‌ها به‌صورت مجزا عمل نمی‌کنند بلکه در قالب شبکه‌ای از روابط مالی، تجاری و اطلاعاتی با یکدیگر در ارتباط هستند. این ارتباطات می‌تواند موجب انتقال و سرایت ریسک میان شرکت‌ها شود. الحافی و همکاران با استفاده از رویکرد شبکه‌ای نشان دادند که برخی گره‌های سازمانی نقش کلیدی در انتقال ریسک دارند و شناسایی آنها می‌تواند در مدیریت بحران‌های مالی مؤثر باشد. این دیدگاه نشان می‌دهد که تحلیل ریسک ورشکستگی تنها بر مبنای متغیرهای داخلی شرکت کافی نیست و باید تعاملات میان شرکت‌ها نیز مورد توجه قرار گیرد (Al-Hafi et al., 2025).

عوامل محیطی و شرایط کلان اقتصادی نیز در شکل‌گیری درماندگی مالی و ورشکستگی شرکت‌ها نقش دارند. پژوهش یانگ، وانگ و یوان نشان داد که رخدادهای فاجعه‌بار و شوک‌های محیطی می‌توانند سرمایه‌گذاری بنگاه‌ها را کاهش داده و ریسک عملیاتی و مالی آنها را افزایش دهند. چنین نتایجی بیانگر آن است که شرکت‌ها در محیطی پویا و متأثر از عوامل بیرونی فعالیت می‌کنند و مدل‌های پیش‌بینی باید توانایی لحاظ کردن این پیچیدگی‌ها را داشته باشند (Yang et al., 2026).

از منظر ثبات مالی نیز مطالعات اخیر بر اهمیت توجه به ابعاد جدید عملکرد شرکت‌ها تأکید کرده‌اند. گائو، ژانگ و لی نشان دادند که ادغام معیارهای محیط‌زیستی، اجتماعی و حاکمیتی (ESG) می‌تواند با ثبات مالی شرکت‌ها در ارتباط باشد، هرچند میان اهداف پایداری و عملکرد مالی کوتاه‌مدت نوعی مبادله وجود دارد. این یافته‌ها حاکی از آن است که ارزیابی ریسک ورشکستگی باید فراتر از شاخص‌های سنتی مالی بوده و ابعاد نوظهور عملکرد سازمانی را نیز مدنظر قرار دهد (Gao et al., 2025).

در کنار این تحولات، توسعه مدل‌های پیشرفته پیش‌بینی مالی نیز به بهبود تحلیل ریسک کمک کرده است. فراز، فاطمه و رادولسکو در بررسی مدل‌های نوین پیش‌بینی مالی نشان دادند که رویکردهای جدید قادرند عملکردی فراتر از برخی مدل‌های سنتی و حتی بخشی از الگوریتم‌های یادگیری ماشین ارائه دهند. این موضوع بیانگر رقابت و تکامل مستمر روش‌های پیش‌بینی در حوزه مالی است و اهمیت ارزیابی تجربی الگوریتم‌های مختلف را برای انتخاب مدل‌های کارآمدتر نشان می‌دهد (Fraz et al., 2026).

همچنین مطالعات مرتبط با ریسک سیستماتیک و اطلاعات بازار نشان داده‌اند که کیفیت و نوع اطلاعات در دسترس سرمایه‌گذاران می‌تواند بر ارزیابی ریسک اثرگذار باشد. معمارپور و همکاران نشان دادند که تحلیل اخبار مالی می‌تواند در ارزیابی ریسک سیستماتیک دارایی‌ها مؤثر باشد. از سوی دیگر، کوراتولا و همکاران نشان دادند که احساسات سرمایه‌گذاران می‌تواند بازده بخش‌های مختلف بازار را تحت تأثیر قرار دهد. همچنین بکر و مکاستی تأکید کرده‌اند که انتشار اطلاعات نادرست و اخبار جعلی می‌تواند پیامدهای اقتصادی قابل توجهی ایجاد کند. این مطالعات اهمیت استفاده از داده‌های عینی و قابل اتکا مانند اطلاعات صورت‌های مالی را در توسعه مدل‌های پیش‌بینی برجسته می‌سازند (Bakir & McStay, 2018; Curatola et al., 2016; Memarpour et al., 2025).

با وجود پیشرفت‌های قابل توجه در حوزه پیش‌بینی ورشکستگی و توسعه الگوریتم‌های هوش مصنوعی، هنوز خلأ پژوهشی مهمی در زمینه مقایسه عملکرد الگوریتم‌های یادگیری ماشین در پیش‌بینی ورشکستگی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار ایران وجود دارد. بخش قابل توجهی از مطالعات داخلی بر پیش‌بینی درماندگی مالی یا

بازده سهام متمرکز بوده‌اند و پژوهش‌های معدودی به بررسی جامع عملکرد الگوریتم‌های پیشرفته یادگیری ماشین در شناسایی شرکت‌های در معرض ورشکستگی پرداخته‌اند. در این میان، مطالعه محمودجانلو و همکاران نشان داد که الگوریتم درخت تصمیم توانایی مناسبی در پیش‌بینی ورشکستگی دارد و مطالعه حمیدی و همکاران نیز بر اهمیت شناسایی زود هنگام درماندگی مالی تأکید کرده است، اما همچنان نیاز به بررسی الگوریتم‌های پیشرفته‌تر و ارزیابی دقیق‌تر متغیرهای مؤثر بر پیش‌بینی ورشکستگی احساس می‌شود (Hamidi et al., 2024; Mahmoudjanlou et al., 2022).

علاوه بر این، رخدادهای مالی بزرگ در سطح جهانی، از جمله فروپاشی مؤسسات مالی برجسته، اهمیت پیش‌بینی بحران‌های مالی را بیش از پیش آشکار ساخته است. مطالعه الشاطر درباره فروپاشی کردیت سوئیس نشان داد که ضعف در مدیریت ریسک و ناتوانی در شناسایی نشانه‌های هشداردهنده می‌تواند پیامدهای گسترده‌ای برای کل نظام مالی ایجاد کند. این شواهد ضرورت توسعه مدل‌های دقیق و هوشمند برای شناسایی زود هنگام شرکت‌های در معرض بحران را برجسته می‌کند (Alshater, 2026). بنابراین، هدف پژوهش حاضر پیش‌بینی ریسک ورشکستگی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار با استفاده از الگوریتم‌های هوش مصنوعی مبتنی بر داده‌های صورت‌های مالی و شناسایی مهم‌ترین متغیرهای مؤثر بر این پیش‌بینی است.

روش پژوهش و مواد

این پژوهش از نظر هدف کاربردی و از نظر ماهیت در زمره تحقیقات کمی و تجربی قرار می‌گیرد. رویکرد پژوهش از نوع توصیفی - تحلیلی است و برای بررسی روابط میان متغیرها از روش‌های اقتصادسنجی و الگوریتم‌های یادگیری ماشین استفاده شده است. هدف اصلی پژوهش، پیش‌بینی ریسک ورشکستگی شرکت‌های بورسی با استفاده از داده‌های صورت‌های مالی و الگوریتم‌های هوش مصنوعی و همچنین بررسی عوامل مؤثر بر آن است. در این راستا از الگوریتم‌های یادگیری ماشین برای شناسایی الگوهای مرتبط با ورشکستگی و از مدل‌های اقتصادسنجی برای تحلیل روابط میان متغیرهای پژوهش استفاده شده است.

جامعه آماری این پژوهش شامل کلیه شرکت‌های پذیرفته‌شده در بورس اوراق بهادار است. به منظور انتخاب نمونه، شرکت‌هایی انتخاب شدند که اطلاعات مالی آن‌ها طی دوره زمانی مورد بررسی به طور کامل در دسترس بوده و در طول دوره تحقیق تغییر سال مالی نداشته باشند. همچنین شرکت‌های فعال در صنعت بانکداری، بیمه و واسطه‌گری مالی به دلیل ماهیت متفاوت فعالیت و ساختار مالی از نمونه حذف شدند. پس از اعمال این محدودیت‌ها و با استفاده از روش غربالگری، شرکت‌هایی که شرایط لازم را داشته‌اند به عنوان نمونه پژوهش انتخاب شدند و داده‌های آن‌ها طی دوره زمانی مورد بررسی جمع‌آوری و تحلیل گردید.

داده‌های مورد نیاز این پژوهش از صورت‌های مالی شرکت‌ها، گزارش‌های سالانه و پایگاه‌های اطلاعاتی مالی استخراج شده است. اطلاعات مربوط به متغیرهای مالی از صورت‌های مالی حسابرسی‌شده شرکت‌ها و سامانه‌های اطلاعاتی مرتبط با بازار سرمایه گردآوری شده است. همچنین داده‌های مربوط به ویژگی‌های ساختاری شرکت‌ها مانند اندازه، سن و سهم بازار از گزارش‌های مالی و پایگاه‌های داده مالی استخراج شده‌اند. پس از جمع‌آوری داده‌ها، اطلاعات مورد نیاز پردازش و برای انجام تحلیل‌های آماری و مدل‌سازی آماده‌سازی شد.

در این پژوهش متغیر وابسته بیانگر ریسک ورشکستگی شرکت‌ها است که با استفاده از مدل‌های پیش‌بینی و شاخص‌های مالی مرتبط برآورد شده است. متغیرهای مستقل شامل مجموعه‌ای از شاخص‌های مالی و ویژگی‌های ساختاری شرکت‌ها از جمله اندازه شرکت، سهم بازار، سن شرکت، وجه نقد آزاد، تمرکز صنعتی و سایر شاخص‌های مرتبط با وضعیت مالی شرکت‌ها هستند. همچنین در برخی مدل‌ها از وقفه متغیر وابسته و شاخص‌های نوسان یا انحراف ریسک ورشکستگی نیز به‌عنوان متغیرهای توضیحی استفاده شده است. این متغیرها با هدف بررسی عوامل مؤثر بر تغییرات ریسک ورشکستگی و بهبود قدرت پیش‌بینی مدل‌ها در تحلیل وارد شده‌اند.

برای تحلیل داده‌ها از دو دسته روش استفاده شده است:

در مرحله نخست، به منظور پیش‌بینی ریسک ورشکستگی شرکت‌ها از الگوریتم‌های یادگیری ماشین شامل جنگل تصادفی و جنگل تصادفی متوازن استفاده شد. عملکرد این مدل‌ها با استفاده از معیارهایی مانند دقت، یادآوری، شاخص F_1 ، منحنی ROC و مساحت زیر منحنی (AUC) ارزیابی گردید. همچنین برای بررسی اهمیت متغیرها در پیش‌بینی ورشکستگی از شاخص اهمیت ویژگی‌ها در مدل جنگل تصادفی استفاده شد.

در مرحله دوم، برای بررسی روابط میان متغیرهای پژوهش و تحلیل پویایی‌های زمانی از مدل داده‌های تابلویی پویا با روش گشتاورهای تعمیم‌یافته استفاده گردید. این روش به دلیل توانایی در کنترل مشکل درون‌زایی متغیرها و وجود متغیر وابسته وقفه‌دار در مدل انتخاب شده است. همچنین برای ارزیابی اعتبار ابزارهای مورد استفاده در مدل از آزمون Hansen J استفاده شد.

یافته‌ها

در این پژوهش به‌منظور پیش‌بینی احتمال ورشکستگی شرکت‌های بورسی با استفاده از داده‌های استخراج‌شده از صورت‌های مالی، از الگوریتم‌های یادگیری ماشین مبتنی بر درخت تصمیم استفاده شده است. به‌طور مشخص، دو رویکرد «جنگل تصادفی» و «جنگل تصادفی متوازن» به کار گرفته شد. الگوریتم جنگل تصادفی با ایجاد مجموعه‌ای از درخت‌های تصمیم و تجمیع نتایج آن‌ها، قادر است الگوهای پیچیده موجود در داده‌های مالی را شناسایی کرده و دقت پیش‌بینی را افزایش دهد. این الگوریتم با استفاده از نمونه‌گیری تصادفی از داده‌ها و متغیرها، از بیش‌برازش جلوگیری کرده و عملکرد پایدارتری نسبت به یک درخت تصمیم منفرد ارائه می‌دهد.

با این حال، در مسائل پیش‌بینی ورشکستگی معمولاً با عدم توازن در داده‌ها مواجه هستیم؛ به‌گونه‌ای که تعداد شرکت‌های ورشکسته بسیار کمتر از شرکت‌های سالم است. این وضعیت می‌تواند باعث شود مدل‌های استاندارد مانند جنگل تصادفی تمایل بیشتری به پیش‌بینی کلاس اکثریت (شرکت‌های غیرورشکسته) داشته باشند و در شناسایی موارد ورشکستگی عملکرد ضعیف‌تری نشان دهند. به همین دلیل در این مطالعه از نسخه اصلاح‌شده این الگوریتم، یعنی جنگل تصادفی متوازن، نیز استفاده شد. در این روش با ایجاد تعادل در نمونه‌های هر کلاس در فرآیند آموزش، تلاش می‌شود مدل حساسیت بیشتری نسبت به کلاس اقلیت (شرکت‌های ورشکسته) داشته باشد و توانایی شناسایی این موارد افزایش یابد.

برای سنجش عملکرد مدل‌های مورد استفاده، چندین شاخص ارزیابی محاسبه شد. این شاخص‌ها امکان مقایسه دقیق‌تر توانایی مدل‌ها در تشخیص شرکت‌های در معرض ورشکستگی را فراهم می‌کنند:

- **AUC (Area Under the Curve)**: مساحت زیر منحنی ROC که بیانگر توانایی مدل در تفکیک شرکت‌های ورشکسته از غیرورشکسته است. مقدار بالاتر این شاخص نشان‌دهنده قدرت تفکیک بیشتر مدل است.

- **ROC Curve**: نموداری که رابطه بین نرخ مثبت درست (True Positive Rate) و نرخ مثبت کاذب (False Positive Rate) را نشان می‌دهد و عملکرد مدل در سطوح مختلف آستانه تصمیم‌گیری را نمایش می‌دهد.

- **Precision**: نسبت شرکت‌هایی که به‌درستی به‌عنوان ورشکسته پیش‌بینی شده‌اند به کل شرکت‌هایی که مدل آن‌ها را ورشکسته پیش‌بینی کرده است.

- **Recall**: نسبت شرکت‌های ورشکسته‌ای که به‌درستی توسط مدل شناسایی شده‌اند به کل شرکت‌های واقعاً ورشکسته.

- **F1 Score**: میانگین موزون شاخص‌های Precision و Recall که تعادل میان دقت پیش‌بینی و توانایی شناسایی موارد ورشکستگی را نشان می‌دهد.

- **Accuracy**: نسبت کل پیش‌بینی‌های صحیح مدل به کل مشاهدات.

به‌منظور مقایسه عملکرد دو مدل جنگل تصادفی و جنگل تصادفی متوازن در پیش‌بینی احتمال ورشکستگی شرکت‌های بورسی، معیارهای AUC، دقت (Precision)، یادآوری (Recall)، شاخص F1 و دقت کلی (Accuracy) محاسبه و تحلیل شدند. این شاخص‌ها تصویری جامع از توانایی مدل‌ها در تشخیص صحیح شرکت‌های در معرض ورشکستگی و همچنین اجتناب از پیش‌بینی‌های نادرست ارائه می‌دهند. نتایج حاصل از این ارزیابی‌ها در جدول (۱) ارائه شده است.


جدول ۱. نتایج عملکرد مدل‌های جنگل تصادفی و جنگل تصادفی متوازن در پیش‌بینی ورشکستگی

| مدل | AUC | دقت | یادآوری | شاخص F1 | دقت کلی |
|--------------------|-------|-------|---------|---------|---------|
| جنگل تصادفی | ۰/۴۵۳ | ۰/۰۰۰ | ۰/۰۰۰ | ۰/۰۰۰ | ۰/۸۵۵ |
| جنگل تصادفی متوازن | ۰/۴۲۶ | ۰/۳۳۳ | ۰/۲۱۱ | ۰/۲۵۸ | ۰/۸۲۴ |

بر اساس نتایج ارائه شده در جدول (۱)، عملکرد مدل جنگل تصادفی در شناسایی شرکت‌های در معرض ورشکستگی چندان مطلوب نبوده است. به طوری که مقادیر شاخص‌های Precision، Recall و F1 برای این مدل تقریباً صفر گزارش شده است. در مقابل، دقت کلی مدل در سطح نسبتاً بالایی (حدود ۸۵ درصد) قرار دارد. این موضوع نشان می‌دهد که مدل عمدتاً شرکت‌های غیرورشکسته را به درستی پیش‌بینی کرده و در شناسایی موارد ورشکستگی که تعداد آن‌ها در داده‌ها کمتر است، موفق عمل نکرده است. چنین نتیجه‌ای معمولاً در شرایطی مشاهده می‌شود که داده‌ها با عدم توازن میان کلاس‌ها مواجه باشند و مدل به سمت پیش‌بینی کلاس اکثریت تمایل پیدا کند.

در مقابل، مدل جنگل تصادفی متوازن با وجود آنکه مقدار AUC پایین‌تری نسبت به مدل جنگل تصادفی نشان می‌دهد، توانسته است بخشی از شرکت‌های ورشکسته را شناسایی کند. بر اساس نتایج، مقدار Precision این مدل برابر با ۰.۳۳۳ و مقدار Recall حدود ۰.۲۱۱ گزارش شده است و شاخص F1 نیز به مقدار ۰.۲۵۸ رسیده است. این نتایج بیانگر آن است که استفاده از روش متوازن‌سازی در الگوریتم جنگل تصادفی موجب افزایش حساسیت مدل نسبت به کلاس اقلیت شده و توانایی آن را در شناسایی شرکت‌های دارای ریسک ورشکستگی بهبود داده است.

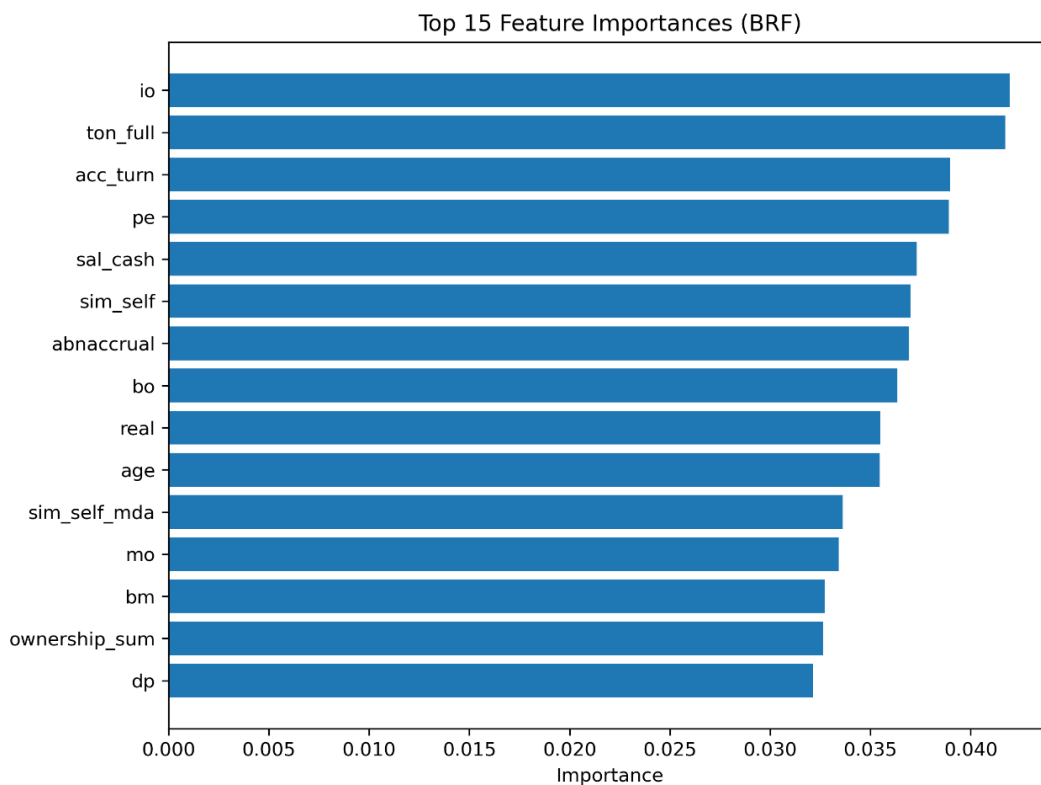
همچنین برای بررسی توانایی تفکیک مدل‌های مورد مطالعه، از منحنی ROC استفاده شد. این منحنی رابطه میان نرخ مثبت واقعی (True Positive Rate) و نرخ مثبت کاذب (False Positive Rate) را در سطوح مختلف آستانه تصمیم‌گیری نشان می‌دهد. شاخص AUC یا مساحت زیر این منحنی به‌عنوان معیاری برای سنجش قدرت تفکیک مدل‌ها در نظر گرفته می‌شود؛ به گونه‌ای که هرچه مقدار این شاخص به عدد یک نزدیک‌تر باشد، مدل توانایی بیشتری در تمایز بین شرکت‌های ورشکسته و غیرورشکسته خواهد داشت.



شکل ۱. منحنی ROC مدل‌های جنگل تصادفی و جنگل تصادفی متوازن

همان گونه که در نمودار (۱) مشاهده می‌شود، مقدار شاخص AUC برای مدل جنگل تصادفی برابر با ۰.۴۵۳ و برای مدل جنگل تصادفی متوازن برابر با ۰.۴۲۶ گزارش شده است. بنابراین، اگرچه تفاوت میان دو مدل چندان زیاد نیست، اما مدل جنگل تصادفی از نظر قدرت تفکیک شرکت‌های ورشکسته از غیرورشکسته عملکرد اندکی بهتر از مدل جنگل تصادفی متوازن نشان داده است.

به منظور بررسی میزان تأثیر هر یک از متغیرهای مالی در پیش‌بینی احتمال ورشکستگی، از شاخص اهمیت متغیرها (Feature Importance) در مدل جنگل تصادفی متوازن استفاده شد. این شاخص نشان می‌دهد که هر متغیر تا چه اندازه در افزایش توان پیش‌بینی مدل نقش داشته و چه سهمی در تصمیم‌گیری نهایی الگوریتم ایفا می‌کند. در شکل (۲)، متغیرهایی که بیشترین اهمیت را در پیش‌بینی ریسک ورشکستگی داشته‌اند، ارائه شده‌اند. این متغیرها به‌عنوان مهم‌ترین شاخص‌های مالی مؤثر در شناسایی شرکت‌های در معرض ورشکستگی قابل توجه هستند.



شکل ۲. مهم‌ترین متغیرهای مؤثر در پیش‌بینی ورشکستگی (مدل جنگل تصادفی متوازن)

بر اساس نتایج ارائه شده در شکل (۲)، برخی از متغیرها نقش مهم‌تری در پیش‌بینی احتمال ورشکستگی شرکت‌ها ایفا کرده‌اند. در میان متغیرهای مورد بررسی، مالکیت نهادی و نسبت گردش حساب‌ها بیشترین میزان اهمیت را در عملکرد مدل نشان داده‌اند. علاوه بر این، نسبت قیمت به سود (P/E) و نسبت وجوه نقد به فروش نیز از جمله متغیرهایی بوده‌اند که سهم قابل توجهی در بهبود توان پیش‌بینی مدل داشته‌اند. در مقابل، متغیرهایی نظیر تمرکز مالکیت و متغیر dp اهمیت کمتری در فرآیند پیش‌بینی نشان داده‌اند. این نتایج بیانگر آن است که ترکیبی از شاخص‌های مالی و متغیرهای مرتبط با ساختار مالکیت و حاکمیت شرکتی می‌تواند در شناسایی شرکت‌های دارای ریسک مالی بالا مؤثر باشد. به بیان دیگر، متغیرهایی که منعکس‌کننده وضعیت عملکرد مالی شرکت و همچنین ساختار نظارتی آن هستند، نقش مهمی در تشخیص شرکت‌های در معرض ورشکستگی دارند. بنابراین استفاده هم‌زمان از شاخص‌های مالی و متغیرهای مرتبط با ویژگی‌های حاکمیتی می‌تواند دقت مدل‌های پیش‌بینی را افزایش دهد. برای ارزیابی دقیق‌تر عملکرد مدل‌های مورد استفاده، از ماتریس اشتباهات (Confusion Matrix) نیز استفاده شد. این ماتریس امکان بررسی نحوه طبقه‌بندی صحیح و نادرست مشاهدات را فراهم می‌کند و شامل چهار جزء اصلی است:

• FN (True Negative): تعداد شرکت‌های غیرورشکسته که به‌درستی به‌عنوان غیرورشکسته شناسایی شده‌اند.

- FP (False Positive): تعداد شرکت‌های غیرورشکسته که به اشتباه در گروه شرکت‌های ورشکسته قرار گرفته‌اند.
 - FN (False Negative): تعداد شرکت‌های ورشکسته که به اشتباه به‌عنوان شرکت‌های سالم پیش‌بینی شده‌اند.
 - TP (True Positive): تعداد شرکت‌های ورشکسته که مدل آن‌ها را به‌درستی شناسایی کرده است.
- نتایج مربوط به ماتریس اشتباهات برای مدل‌های جنگل تصادفی و جنگل تصادفی متوازن در جدول (۴-۷) ارائه شده است.

جدول ۲. ماتریس اشتباهات مدل‌های جنگل تصادفی و جنگل تصادفی متوازن

| مدل | TN | EP | FN | TP |
|--------------------|-----|----|----|----|
| جنگل تصادفی | ۱۱۲ | ۰ | ۱۹ | ۰ |
| جنگل تصادفی متوازن | ۱۰۴ | ۸ | ۱۵ | ۴ |

همان‌گونه که در جدول (۲) مشاهده می‌شود، مدل جنگل تصادفی تمامی شرکت‌های غیرورشکسته را به‌درستی شناسایی کرده است ($TN=112$)، اما هیچ‌یک از شرکت‌های ورشکسته را تشخیص نداده است ($TP=0$). این نتیجه نشان می‌دهد که مدل جنگل تصادفی در شرایط وجود عدم توازن در داده‌ها، عمدتاً بر پیش‌بینی کلاس اکثریت یعنی شرکت‌های غیرورشکسته تمرکز داشته و در شناسایی موارد ورشکستگی عملکرد مناسبی ارائه نکرده است.

در مقابل، مدل جنگل تصادفی متوازن اگرچه با تعدادی خطای مثبت کاذب همراه بوده است ($FP=8$)، اما توانسته است چهار شرکت ورشکسته را به‌درستی شناسایی کند ($TP=4$). بنابراین می‌توان گفت که این مدل در تشخیص موارد ورشکستگی نسبت به مدل جنگل تصادفی عملکرد بهتری داشته است. با این حال، مقدار نسبتاً بالای خطای منفی کاذب ($FN=15$) نشان می‌دهد که همچنان بخش قابل توجهی از شرکت‌های ورشکسته توسط مدل شناسایی نشده‌اند و پیش‌بینی ورشکستگی در داده‌های مورد بررسی همچنان با چالش‌هایی همراه است.

در این بخش، بخشی از نمرات کارایی عملیاتی شرکت‌ها که بر اساس مدل مرز تصادفی محاسبه شده‌اند ارائه می‌شود. با توجه به حجم زیاد داده‌ها، در جدول (۴-۸) تنها نمونه‌ای از نتایج گزارش شده است. این نمونه شامل تعدادی از شرکت‌ها در سال‌های مختلف و همچنین برخی از شرکت‌هایی است که بالاترین مقادیر کارایی عملیاتی را کسب کرده‌اند. هدف از ارائه این نمونه‌ها، نشان دادن دامنه تغییرات و تنوع مقادیر کارایی عملیاتی در میان شرکت‌های مورد بررسی است.

جدول ۳. نمونه‌ای از نمرات ورشکستگی بر اساس مدل مرز تصادفی

| شرکت | سال | ورشکستگی |
|------|------|----------|
| C۰۳۳ | ۱۳۹۷ | ۱ |
| C۰۶۸ | ۱۳۹۷ | ۱ |
| C۰۲۴ | ۱۳۹۸ | ۱ |
| C۰۷۷ | ۱۳۹۸ | ۱ |
| C۰۹۰ | ۱۳۹۸ | ۱ |
| C۰۶۶ | ۱۳۹۹ | ۱ |
| C۰۷۲ | ۱۳۹۹ | ۱ |
| C۰۱۶ | ۱۴۰۰ | ۱ |
| C۰۱۸ | ۱۴۰۰ | ۱ |
| C۰۲۹ | ۱۴۰۰ | ۱ |
| C۰۷۷ | ۱۴۰۰ | ۱ |
| C۰۲۸ | ۱۴۰۱ | ۱ |
| C۰۶۶ | ۱۴۰۱ | ۱ |
| C۰۸۴ | ۱۴۰۱ | ۱ |
| C۰۳۸ | ۱۴۰۲ | ۱ |

حسابداری، امور مالی و هوش محاسباتی

| | | |
|-------|------|------|
| ۱ | ۱۴۰۲ | C۰۶۲ |
| ۱ | ۱۴۰۲ | C۰۸۶ |
| ۱ | ۱۴۰۳ | C۰۰۸ |
| ۱ | ۱۴۰۳ | C۰۲۵ |
| ۱ | ۱۴۰۳ | C۰۸۶ |
| ۰/۹۶۱ | ۱۴۰۱ | C۰۵۸ |
| ۰/۹۵۸ | ۱۴۰۰ | C۰۱۷ |
| ۰/۹۵۵ | ۱۴۰۳ | C۰۴۱ |
| ۰/۹۴۷ | ۱۳۹۸ | C۰۸۶ |
| ۰/۹۱۹ | ۱۳۹۹ | C۰۷۶ |
| ۰/۸۵۹ | ۱۳۹۸ | C۰۸۲ |
| ۰/۸۵۳ | ۱۳۹۸ | C۰۷۸ |
| ۰/۸۵۳ | ۱۴۰۰ | C۰۳۳ |
| ۰/۸۴۴ | ۱۴۰۰ | C۰۲۳ |
| ۰/۸۴۲ | ۱۳۹۷ | C۰۲۱ |
| ۰/۸۳۹ | ۱۴۰۱ | C۰۷۸ |
| ۰/۸۳۳ | ۱۳۹۹ | C۰۵۱ |
| ۰/۸۳۱ | ۱۳۹۹ | C۰۸۸ |
| ۰/۸۲۹ | ۱۴۰۳ | C۰۵۹ |

بر اساس اطلاعات ارائه شده در جدول (۳)، بخش قابل توجهی از شرکت‌های مورد بررسی در دوره زمانی مطالعه دارای مقادیر نسبتاً پایین در شاخص ریسک ورشکستگی بوده‌اند که بیانگر وضعیت مالی نسبتاً پایدار و احتمال کمتر بروز بحران‌های مالی در این شرکت‌ها است. با این حال، بررسی دقیق‌تر داده‌ها نشان می‌دهد که برخی شرکت‌ها مقادیر بالاتری از ریسک ورشکستگی را تجربه کرده‌اند که حاکی از وجود تفاوت‌های قابل توجه در سطح ریسک مالی میان شرکت‌های نمونه است. به‌طور مشخص، برخی شرکت‌ها در برخی سال‌ها دارای مقادیر بالاتر شاخص ریسک ورشکستگی بوده‌اند که می‌تواند بیانگر فشارهای مالی، کاهش توانایی در ایفای تعهدات یا ضعف در ساختار مالی آن‌ها باشد. این نتایج نشان می‌دهد که اگرچه در مجموع بسیاری از شرکت‌ها از وضعیت مالی نسبتاً باثباتی برخوردار بوده‌اند، اما همچنان ناهمگنی قابل توجهی در میزان ریسک ورشکستگی میان شرکت‌ها وجود دارد که می‌تواند مبنای تحلیل‌های بیشتر در بخش‌های بعدی پژوهش قرار گیرد.

به‌منظور بررسی روند تغییرات ریسک ورشکستگی شرکت‌ها در طول دوره زمانی مورد مطالعه، شاخص‌های آماری توصیفی مربوط به مقادیر این شاخص برای هر سال به‌صورت جداگانه محاسبه شده است. این شاخص‌ها شامل میانگین، میانه، انحراف معیار و تعداد مشاهدات است که می‌توانند تصویری جامع‌تر از سطح کلی ریسک ورشکستگی و میزان پراکندگی آن در میان شرکت‌های نمونه ارائه دهند. نتایج حاصل از این محاسبات در جدول (۴) ارائه شده است که از طریق آن می‌توان روند تغییرات ریسک ورشکستگی شرکت‌ها را در فاصله زمانی سال‌های ۱۳۹۷ تا ۱۴۰۳ به‌طور دقیق‌تر مورد بررسی و تحلیل قرار داد.


جدول ۴. میانگین و شاخص‌های آماری نرخ ورشکستگی سالانه شرکت‌ها

| سال | میانگین | میانه | انحراف معیار | تعداد مشاهدات |
|------|---------|-------|--------------|---------------|
| ۱۳۹۷ | ۰/۴۸۸ | ۰/۴۳۸ | ۰/۱۷۷ | ۵۲ |
| ۱۳۹۸ | ۰/۵۴۰ | ۰/۴۵۲ | ۰/۲۱۹ | ۴۱ |
| ۱۳۹۹ | ۰/۵۵۴ | ۰/۵۱۰ | ۰/۱۸۹ | ۴۱ |
| ۱۴۰۰ | ۰/۵۴۷ | ۰/۴۶۶ | ۰/۲۰۸ | ۴۴ |
| ۱۴۰۱ | ۰/۵۴۰ | ۰/۵۱۰ | ۰/۱۷۹ | ۴۶ |
| ۱۴۰۲ | ۰/۵۳۲ | ۰/۴۸۳ | ۰/۱۸۸ | ۴۵ |
| ۱۴۰۳ | ۰/۵۵۲ | ۰/۵۰۵ | ۰/۲۰۱ | ۴۴ |

بر اساس نتایج ارائه شده در جدول (۴)، میانگین شاخص‌های مرتبط با ریسک ورشکستگی شرکت‌های مورد بررسی در طول دوره مطالعه در بازه‌ای حدود ۰.۴۸۸ تا ۰.۵۵۴ قرار داشته است. کمترین مقدار میانگین به سال ۱۳۹۷ با حدود ۰.۴۸۸ مربوط می‌شود، در حالی که بیشترین مقدار آن در سال ۱۳۹۹ و در حدود ۰.۵۵۴ مشاهده شده است. این مقادیر نشان می‌دهد که وضعیت ریسک مالی شرکت‌ها در سال‌های مختلف تغییراتی را تجربه کرده است.

همچنین مقادیر میانه در اغلب سال‌ها فاصله زیادی با میانگین ندارند که این موضوع بیانگر توزیع نسبتاً متعادل مقادیر شاخص‌های مرتبط با ریسک ورشکستگی در میان شرکت‌ها است. از سوی دیگر، انحراف معیار که در محدوده تقریبی ۰.۱۷۷ تا ۰.۲۱۹ قرار دارد، نشان‌دهنده وجود تفاوت و پراکندگی قابل توجه در سطح ریسک ورشکستگی میان شرکت‌ها در هر سال است.

به‌طور کلی، بررسی روند تغییرات این شاخص‌ها نشان می‌دهد که نوسانات میانگین ریسک ورشکستگی در طول دوره مورد بررسی چندان شدید نبوده است. بنابراین می‌توان گفت وضعیت کلی ریسک مالی شرکت‌ها در این بازه زمانی از ثبات نسبی برخوردار بوده، هرچند تفاوت‌هایی میان شرکت‌ها از نظر سطح ریسک ورشکستگی همچنان مشاهده می‌شود.



شکل ۳. میانگین ورشکستگی سالانه شرکت‌ها

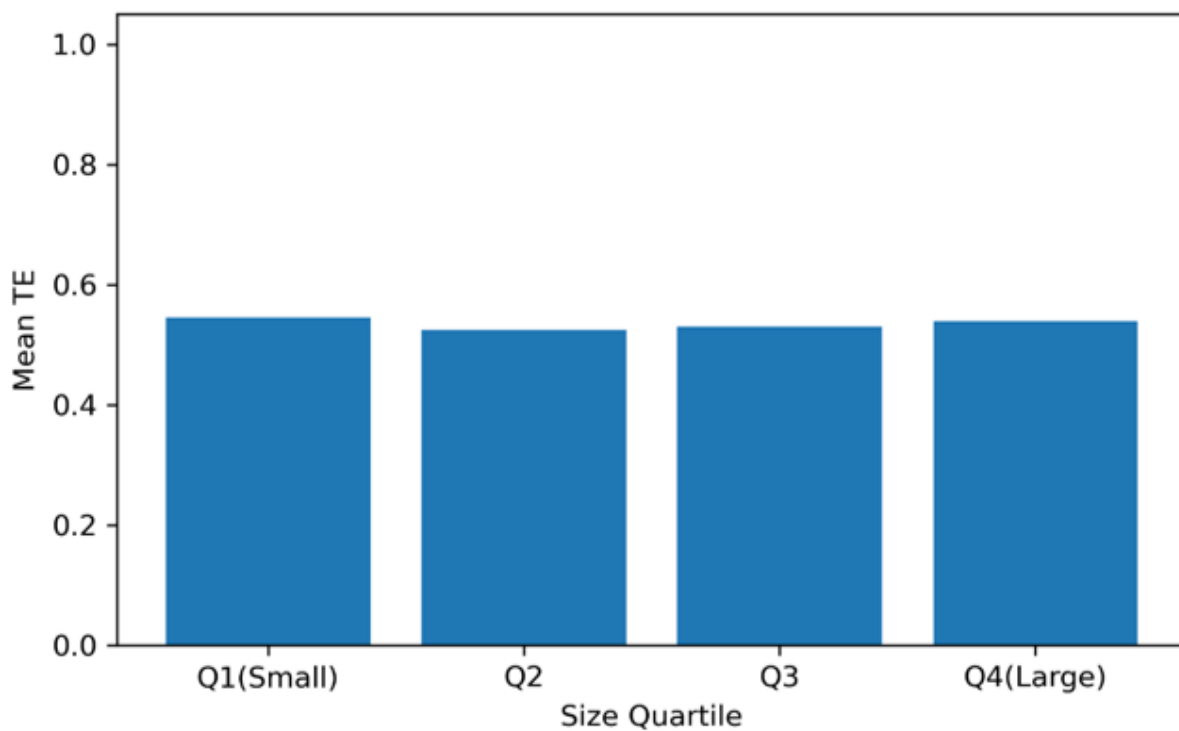
به‌منظور بررسی تفاوت‌های ریسک ورشکستگی میان شرکت‌ها بر اساس اندازه آن‌ها، شرکت‌های مورد بررسی بر مبنای میزان دارایی به چهار گروه کوارتالی تقسیم شدند. در این تقسیم‌بندی، گروه Q1 شامل شرکت‌های کوچک‌تر و گروه Q4 شامل شرکت‌های بزرگ‌تر از نظر سطح دارایی‌ها است. سپس شاخص‌های آماری توصیفی شامل میانگین، میانه، انحراف معیار و تعداد مشاهدات برای هر یک از این گروه‌ها محاسبه شد. نتایج این محاسبات در جدول (۵) ارائه شده و امکان مقایسه وضعیت ریسک ورشکستگی در میان شرکت‌های با اندازه‌های مختلف را فراهم می‌کند.

جدول ۵. میانگین و شاخص‌های آماری نرخ ورشکستگی بر حسب اندازه شرکت

| اندازه شرکت | میانگین | میانه | انحراف معیار | تعداد مشاهدات |
|-------------|---------|-------|--------------|---------------|
| Q1 | ۰/۵۴۵ | ۰/۴۸۴ | ۰/۲۰۷ | ۷۹ |
| Q2 | ۰/۵۲۵ | ۰/۴۶۲ | ۰/۱۹۰ | ۷۸ |
| Q3 | ۰/۵۳۰ | ۰/۴۷۴ | ۰/۱۸۸ | ۷۸ |
| Q4 | ۰/۵۳۹ | ۰/۴۹۲ | ۰/۱۹۱ | ۷۸ |

بر اساس نتایج جدول (۵)، تفاوت میانگین شاخص‌های مرتبط با ریسک ورشکستگی میان گروه‌های مختلف اندازه شرکت چندان قابل توجه نیست و مقادیر آن در محدوده‌ای حدود ۰.۵۲۵ تا ۰.۵۴۵ قرار دارد. بالاترین میانگین مربوط به شرکت‌های کوچک‌تر (Q1) با مقدار حدود ۰.۵۴۵ است و پس از آن شرکت‌های بزرگ‌تر (Q4) با میانگین حدود ۰.۵۳۹ قرار دارند. این نتایج نشان می‌دهد که شرکت‌ها در اندازه‌های مختلف از نظر سطح ریسک ورشکستگی تفاوت چشمگیری با یکدیگر نداشته‌اند، هرچند در نمونه مورد بررسی، شرکت‌های کوچک‌تر وضعیت نسبتاً بهتری را نشان داده‌اند.

همچنین مقدار انحراف معیار که در تمامی گروه‌ها در حدود ۰.۱۹ قرار دارد، بیانگر وجود پراکندگی قابل توجه در سطح ریسک ورشکستگی در درون هر گروه اندازه است. به‌طور کلی، نتایج نشان می‌دهد که اندازه شرکت در دوره مورد بررسی نقش تعیین‌کننده و قاطعی در تفاوت سطح ریسک ورشکستگی نداشته است، هرچند اختلاف اندکی به نفع شرکت‌های کوچک‌تر مشاهده می‌شود.



شکل ۴. میانگین ورشکستگی بر حسب اندازه شرکت

به‌منظور بررسی اثر ریسک ورشکستگی بر عملکرد آتی شرکت‌ها، از مدل داده‌های تابلویی پویا با استفاده از روش گشتاورهای تعمیم‌یافته (GMM) استفاده شد. در این مدل، متغیر وابسته بیانگر وضعیت مالی یا ریسک ورشکستگی شرکت‌ها در دوره‌های آتی است و برای تبیین آن مجموعه‌ای از متغیرهای توضیحی در نظر گرفته شده است. این متغیرها شامل احتمال ورشکستگی، اندازه شرکت، سهم بازار، سن شرکت، وجه نقد آزاد، تمرکز صنعتی، انحراف ریسک ورشکستگی و همچنین وقفه متغیر وابسته هستند. به‌کارگیری روش گشتاورهای تعمیم‌یافته در این پژوهش به این دلیل است که این روش توانایی کنترل مشکلات اقتصادسنجی رایج در مدل‌های پویا را دارد. به‌ویژه زمانی که متغیر وابسته با وقفه در مدل وارد می‌شود، امکان بروز تورش در برآوردها وجود دارد که روش GMM می‌تواند آن را تا حد زیادی کاهش دهد. همچنین این روش با استفاده از متغیرهای ابزاری مناسب، مسئله درون‌زایی احتمالی میان متغیرها را کنترل کرده و برآوردهای قابل اتکاتری از ضرایب مدل ارائه می‌دهد.

جدول ۶. نتایج برآورد مدل پانل پویا با روش گشتاورهای تعمیم یافته

| متغیر | ضریب | آماره t | سطح معناداری |
|------------------|----------|---------|--------------|
| احتمال ورشکستگی | ۰/۰۳۴۵ | ۰/۰۱۵۵ | ۰/۹۸۷۷ |
| اندازه شرکت | ۴/۳۴۴ | ۱/۰۶۰۸ | ۰/۲۸۸۸ |
| سهم بازار | ۰/۰۲۵۵ | ۰/۱۴۰۷ | ۰/۸۸۸۱ |
| سن شرکت | -۱/۴۶۷۹ | -۰/۸۸۹۱ | ۰/۳۷۳۹ |
| وجه نقد آزاد | ۲۹/۰۴۳۹ | ۲/۴۳۸۷ | ۰/۰۱۴۷ |
| تمرکز صنعتی | ۸/۴۱۰۸ | ۲/۷۹۴۹ | ۰/۰۰۵۲ |
| انحراف ریسک تقلب | -۲۶/۱۸۷۶ | -۲/۲۰۷۵ | ۰/۰۲۷۳ |
| تأخیر کارایی | -۰/۶۰۶۴ | -۱/۷۴۳۳ | ۰/۰۸۱۳ |

نتایج برآورد مدل نشان می‌دهد که برخی از متغیرهای توضیحی اثر معناداری بر وضعیت آتی شرکت‌ها از نظر ریسک ورشکستگی دارند. بر این اساس، متغیرهای وجه نقد آزاد و تمرکز صنعتی دارای اثر مثبت و معنادار بر وضعیت مالی آینده شرکت‌ها هستند. این یافته بیانگر آن است که شرکت‌هایی که از منابع نقدی آزاد بیشتری برخوردارند یا در صنایع متمرکزتر فعالیت می‌کنند، از شرایط مالی باثبات‌تری برخوردار بوده و در نتیجه احتمال مواجهه با مشکلات مالی و ورشکستگی در آن‌ها کمتر است. همچنین نتایج نشان می‌دهد که انحراف ریسک ورشکستگی دارای اثر منفی و معنادار بر وضعیت مالی آتی شرکت‌ها است. این موضوع بیانگر آن است که افزایش نوسانات در شاخص‌های مرتبط با ریسک ورشکستگی می‌تواند پیامدهای نامطلوبی برای عملکرد مالی آینده شرکت‌ها به همراه داشته باشد و احتمال بروز مشکلات مالی را افزایش دهد. از سوی دیگر، وقفه متغیر وابسته با ضریب منفی و در سطح اطمینان ۱۰ درصد معنادار گزارش شده است که نشان‌دهنده وجود نوعی پایداری در وضعیت مالی شرکت‌ها در طول زمان است؛ به این معنا که شرایط مالی ضعیف یا ریسک بالاتر در یک دوره می‌تواند تا حدی در دوره‌های بعد نیز تداوم یابد. در مقابل، سایر متغیرهای وارد شده در مدل از جمله احتمال ورشکستگی پیش‌بینی شده، اندازه شرکت و سهم بازار در این برآورد از نظر آماری معنادار نبوده‌اند.

جدول ۷. آزمون پایایی ابزارها

| آزمون | آماره | مقدار احتمال |
|------------------------------|--------|--------------|
| احتمال ورشکستگی پیش‌بینی شده | ۲/۲۵۹۶ | ۰/۱۳۲۸ |

نتایج آزمون هسن نیز نشان می‌دهد که ابزارهای به کاررفته در برآورد مدل از اعتبار لازم برخوردار هستند و فرضیه صفر مبنی بر صحت ابزارها رد نمی‌شود. این نتیجه بیانگر آن است که متغیرهای ابزاری مورد استفاده در روش گشتاورهای تعمیم یافته مناسب بوده و برآوردهای مدل از نظر اقتصادی قابل اتکا هستند.

فرضیه تحقیق: تخمین ریسک ورشکستگی شرکت‌ها با استفاده از الگوریتم‌های یادگیری ماشین امکان پذیر است.

برای آزمون این فرضیه، از دو الگوریتم یادگیری ماشین شامل جنگل تصادفی و جنگل تصادفی متوازن استفاده شد. نتایج ارائه شده در جدول (۷) نشان می‌دهد که هر دو مدل توانایی شناسایی شرکت‌های در معرض ریسک ورشکستگی را دارند. با این حال، عملکرد مدل جنگل تصادفی متوازن در برخی از شاخص‌های ارزیابی مربوط به تشخیص کلاس اقلیت بهتر از مدل جنگل تصادفی بوده است.

همچنین نتایج نمودار (۴) نشان می‌دهد که اگرچه مقادیر شاخص AUC در سطح متوسط قرار دارند، اما مدل‌های مورد استفاده توانسته‌اند تا حدی میان شرکت‌های دارای ریسک ورشکستگی و شرکت‌های سالم تمایز ایجاد کنند. علاوه بر این، نتایج مربوط به اهمیت متغیرها بیانگر آن است که برخی شاخص‌های مالی و ساختاری شرکت‌ها نقش پررنگ‌تری در پیش‌بینی ریسک ورشکستگی دارند و سهم بیشتری در عملکرد مدل ایفا می‌کنند.

بر این اساس می‌توان نتیجه گرفت که استفاده از الگوریتم‌های یادگیری ماشین، به‌ویژه روش‌های مبتنی بر درخت تصمیم مانند جنگل تصادفی و جنگل تصادفی متوازن، قابلیت قابل قبولی در شناسایی و برآورد ریسک ورشکستگی شرکت‌ها دارند؛ بنابراین فرضیه تحقیق تأیید می‌شود.

بحث و نتیجه‌گیری

نتایج پژوهش حاضر نشان داد که هر دو الگوریتم یادگیری ماشین مورد استفاده، یعنی جنگل تصادفی و جنگل تصادفی متوازن، از قابلیت پیش‌بینی ریسک ورشکستگی شرکت‌های پذیرفته‌شده در بورس برخوردار هستند، اما عملکرد آنها یکسان نبود. یافته‌ها نشان داد که مدل جنگل تصادفی اگرچه دقت کلی نسبتاً بالایی در طبقه‌بندی مشاهدات داشت، اما در شناسایی شرکت‌های ورشکسته عملکرد ضعیفی از خود نشان داد و عملاً بخش عمده‌ای از موارد مربوط به طبقه اقلیت را تشخیص نداد. در مقابل، مدل جنگل تصادفی متوازن با وجود کاهش نسبی در دقت کلی، توانست توانایی بیشتری در شناسایی شرکت‌های دارای ریسک ورشکستگی نشان دهد و مقادیر Recall و F1 بالاتری را ثبت کند. این نتیجه بیانگر آن است که در مسائل مالی مبتنی بر داده‌های نامتوازن، استفاده از رویکردهای متوازن‌سازی داده‌ها می‌تواند به بهبود عملکرد مدل در شناسایی رویدادهای نادر اما مهم منجر شود. از آنجا که ورشکستگی شرکت‌ها در بسیاری از نمونه‌های مالی نسبت به شرکت‌های سالم تعداد کمتری دارد، مدل‌های سنتی یادگیری ماشین معمولاً به سمت طبقه اکثریت گرایش پیدا می‌کنند و همین مسئله موجب کاهش توانایی آنها در شناسایی موارد بحرانی می‌شود. یافته حاضر نشان می‌دهد که توجه به عدم‌توازن داده‌ها در طراحی مدل‌های پیش‌بینی مالی اهمیت اساسی دارد و می‌تواند کارایی عملی مدل را به شکل معناداری افزایش دهد.

برتری نسبی جنگل تصادفی متوازن در شناسایی شرکت‌های در معرض ورشکستگی با مبانی نظری مدیریت ریسک مالی نیز سازگار است. هدف اصلی مدل‌های هشدار زودهنگام، تشخیص دقیق شرکت‌هایی است که در معرض بحران قرار دارند و در این زمینه حساسیت مدل نسبت به طبقه ورشکسته اهمیت بیشتری نسبت به دقت کلی دارد. از این منظر، نتایج پژوهش حاضر نشان می‌دهد که ارزیابی مدل‌های پیش‌بینی ورشکستگی نباید صرفاً بر اساس شاخص دقت کلی انجام شود، بلکه شاخص‌هایی نظیر Recall، Precision و F1 نیز باید مورد توجه قرار گیرند. این موضوع با نتایج پژوهش‌هایی که بر اهمیت تحلیل چندبعدی ریسک و استفاده از معیارهای متنوع ارزیابی تأکید کرده‌اند، همسو است (Fraz et al., 2026; Hamidi et al., 2024).

یکی دیگر از یافته‌های مهم پژوهش حاضر، تأیید قابلیت الگوریتم‌های هوش مصنوعی در تحلیل داده‌های مالی و پیش‌بینی بحران‌های مالی بود. نتایج نشان داد که الگوریتم‌های یادگیری ماشین قادرند الگوهای پنهان میان متغیرهای مالی را استخراج کرده و اطلاعات ارزشمندی درباره احتمال ورشکستگی شرکت‌ها فراهم سازند. این یافته با مطالعاتی که بر نقش هوش مصنوعی در ارتقای تصمیم‌گیری‌های مالی تأکید کرده‌اند، همخوانی دارد. کرمانی و صادقی‌منش نشان دادند که استفاده از الگوریتم‌های هوش مصنوعی می‌تواند کارایی فرایندهای مالی را افزایش دهد و تصمیم‌گیری مبتنی بر داده را بهبود بخشد (Kermani & Sadeghi-Manesh, 2024). همچنین شریفی گزارش کرد که کاربرد هوش مصنوعی در تصمیمات بودجه‌بندی سرمایه‌ای موجب افزایش دقت تحلیل‌ها و کاهش خطاهای پیش‌بینی می‌شود (Sharifi, 2023). از این منظر، یافته‌های پژوهش حاضر تأییدی بر این دیدگاه است که الگوریتم‌های یادگیری ماشین می‌توانند ابزار مؤثری برای مدیریت ریسک و ارزیابی سلامت مالی شرکت‌ها باشند.

یافته‌های پژوهش همچنین با نتایج مطالعات داخلی مرتبط با پیش‌بینی مالی همسو است. دلیلی و همکاران نشان دادند که الگوریتم‌های هوش مصنوعی توانایی پیش‌بینی بازده منفی سهام را دارند و می‌توانند روابط پیچیده میان متغیرهای مالی را شناسایی کنند (Dalili et al., 2025). به‌طور مشابه، پژوهش حاضر نشان داد که این الگوریتم‌ها در حوزه پیش‌بینی ورشکستگی نیز عملکرد مناسبی دارند و قادرند الگوهای مرتبط با بحران مالی را استخراج کنند. همچنین یافته‌های این پژوهش در امتداد نتایج محمودجانلو و همکاران قرار می‌گیرد که کارایی الگوریتم درخت تصمیم را در پیش‌بینی ورشکستگی شرکت‌های بورسی گزارش کرده بودند (Mahmoudjanlou et al., 2022). هر دو مطالعه بر این نکته تأکید دارند که روش‌های مبتنی بر هوش مصنوعی نسبت به بسیاری از رویکردهای سنتی ظرفیت بیشتری برای تحلیل داده‌های مالی پیچیده دارند.

بخش دیگری از یافته‌های پژوهش به تحلیل اهمیت متغیرها اختصاص داشت. نتایج نشان داد که متغیرهایی نظیر مالکیت نهادی، نسبت گردش حساب‌ها، نسبت قیمت به سود و نسبت وجه نقد به فروش بیشترین نقش را در پیش‌بینی ریسک ورشکستگی ایفا می‌کنند. اهمیت مالکیت نهادی را می‌توان از منظر نظریه حاکمیت شرکتی تبیین کرد. حضور سرمایه‌گذاران نهادی معمولاً با نظارت بیشتر بر عملکرد مدیریت، افزایش شفافیت و کنترل بهتر ریسک همراه است. در نتیجه، تغییرات در ساختار مالکیت می‌تواند نشانه مهمی از وضعیت مالی آتی شرکت باشد. این یافته با پژوهش الحافی و همکاران همخوانی دارد که بر نقش ساختارهای سازمانی و شبکه‌های وابستگی در انتقال و مدیریت ریسک تأکید

کرده‌اند (Al-Hafi et al., 2025). همچنین اهمیت شاخص‌های نقدینگی و عملکردی نظیر گردش حساب‌ها و نسبت وجه نقد به فروش با ادبیات درماندگی مالی سازگار است؛ زیرا کاهش توانایی شرکت در ایجاد جریان نقدی و مدیریت سرمایه در گردش معمولاً از نخستین نشانه‌های ضعف مالی محسوب می‌شود (Hamidi et al., 2024).

اهمیت نسبت قیمت به سود نیز از منظر رفتار بازار سرمایه قابل تفسیر است. این نسبت نه تنها بازتاب‌دهنده عملکرد مالی شرکت است، بلکه انتظارات سرمایه‌گذاران درباره آینده شرکت را نیز منعکس می‌کند. در شرایطی که بازار نسبت به چشم‌انداز شرکت بدبین باشد، تغییرات این نسبت می‌تواند نشانه‌ای از افزایش احتمال بحران مالی باشد. این نتیجه با مطالعات مرتبط با احساسات سرمایه‌گذاران و واکنش بازار به اطلاعات مالی همخوانی دارد. کوراتولا و همکاران نشان دادند که احساسات سرمایه‌گذاران می‌تواند بر بازده سهام اثرگذار باشد و رفتار بازار را تحت تأثیر قرار دهد (Curatola et al., 2016). بنابراین، شاخص‌هایی که بازتابی از نگرش سرمایه‌گذاران نسبت به شرکت هستند، می‌توانند در مدل‌های پیش‌بینی ورشکستگی نقش مهمی داشته باشند.

نتایج پژوهش حاضر همچنین نشان داد که میانگین ریسک ورشکستگی شرکت‌ها در طول دوره زمانی مورد مطالعه نوسانات محدودی داشته است و در مجموع وضعیت ریسک مالی شرکت‌های نمونه از ثبات نسبی برخوردار بوده است. این یافته می‌تواند بیانگر آن باشد که اگرچه برخی شرکت‌ها در معرض درماندگی مالی قرار دارند، اما ساختار کلی بازار سرمایه در دوره مورد بررسی با بحران فراگیر مواجه نبوده است. این نتیجه با دیدگاه مطرح‌شده توسط اباد درباره رابطه ریسک و بازده و نقش ثبات مالی در عملکرد بازار سرمایه همسو است (Abad, 2025). همچنین یافته‌های پژوهش با نتایج مطالعات مربوط به ریسک سیستماتیک سازگاری دارد که نشان می‌دهند عوامل خاص شرکت و ویژگی‌های داخلی نقش مهمی در بروز بحران مالی ایفا می‌کنند (Asimit & Li, 2017; Clements & Liao, 2020).

از سوی دیگر، نتایج مربوط به تفاوت ریسک ورشکستگی بر اساس اندازه شرکت نشان داد که اختلاف میان گروه‌های مختلف چندان چشمگیر نیست. این نتیجه بیانگر آن است که در شرایط کنونی بازار سرمایه، صرف اندازه شرکت نمی‌تواند شاخص تعیین‌کننده‌ای برای ارزیابی احتمال ورشکستگی باشد. هرچند برخی مطالعات بر مزایای شرکت‌های بزرگ‌تر از نظر دسترسی به منابع مالی و کاهش ریسک تأکید کرده‌اند، اما یافته حاضر نشان می‌دهد که عوامل دیگری نظیر کیفیت مدیریت، ساختار مالکیت، نقدینگی و عملکرد عملیاتی نقش پررنگ‌تری در تعیین ریسک ورشکستگی دارند. این موضوع با یافته‌های ختن‌لو و همکاران مبنی بر اهمیت عوامل نامشهودی مانند شهرت شرکت در کاهش ریسک مالی همسو است (Khatanlou et al., 2025).

یافته‌های پژوهش حاضر همچنین اهمیت کیفیت اطلاعات مالی را برجسته می‌سازد. از آنجا که مدل‌های یادگیری ماشین بر مبنای داده‌های استخراج‌شده از صورت‌های مالی آموزش می‌بینند، هرگونه تحریف در اطلاعات مالی می‌تواند بر دقت پیش‌بینی تأثیر منفی بگذارد. این نتیجه با پژوهش پورغفار و اقبال مزرعه همسو است که نشان دادند حسابداری خلاقانه می‌تواند تصویر غیرواقعی از وضعیت مالی شرکت ارائه کرده و ریسک ورشکستگی را افزایش دهد (Pourghaffar & Eghbal Mazraeh, 2025). بنابراین، موفقیت مدل‌های پیش‌بینی نه تنها به قدرت الگوریتم بلکه به کیفیت داده‌های ورودی نیز وابسته است.

همچنین یافته‌های پژوهش را می‌توان در چارچوب تحولات اخیر اقتصاد جهانی تفسیر کرد. فروپاشی برخی مؤسسات مالی بزرگ نشان داده است که عدم شناسایی به موقع نشانه‌های هشداردهنده می‌تواند پیامدهای گسترده‌ای برای کل نظام مالی ایجاد کند. الشاطر در مطالعه خود درباره فروپاشی کردیت سوئیس نشان داد که ضعف در مدیریت ریسک و بی‌توجهی به علائم اولیه بحران می‌تواند حتی مؤسسات بزرگ مالی را با شکست مواجه سازد (Alshater, 2026). نتایج پژوهش حاضر نیز اهمیت توسعه سامانه‌های هوشمند هشدار زود هنگام را برای شناسایی شرکت‌های در معرض بحران تأیید می‌کند.

علاوه بر این، نقش عوامل محیطی و شرایط کلان اقتصادی نیز نباید نادیده گرفته شود. یانگ و همکاران نشان دادند که شوک‌های محیطی و رخداد‌های غیرمنتظره می‌توانند وضعیت مالی شرکت‌ها را تحت تأثیر قرار دهند (Yang et al., 2026). همچنین پژوهش گائو و همکاران بر اهمیت ابعاد پایداری و معیارهای ESG در ثبات مالی شرکت‌ها تأکید کرده است (Gao et al., 2025). بنابراین، هرچند مدل حاضر بر داده‌های مالی تمرکز داشته است، اما نتایج آن نشان می‌دهد که توسعه مدل‌های جامع‌تر با در نظر گرفتن عوامل محیطی، حاکمیتی و پایداری می‌تواند دقت پیش‌بینی را افزایش دهد.

از منظر اطلاعات بازار نیز یافته‌های پژوهش حاضر با مطالعات مرتبط با اخبار و اطلاعات مالی همسو است. معمارپور و همکاران نشان دادند که تحلیل اخبار می‌تواند در ارزیابی ریسک دارایی‌ها مؤثر باشد (Memarpour et al., 2025). همچنین بکر و مکاستی تأکید کردند که فضای اطلاعاتی و انتشار اخبار نادرست می‌تواند بر رفتار اقتصادی اثرگذار باشد (Bakir & McStay, 2018). از این رو، تلفیق داده‌های مالی با داده‌های متنی و اطلاعات بازار می‌تواند نسل جدیدی از مدل‌های پیش‌بینی ورشکستگی را شکل دهد که از قدرت تبیینی بیشتری برخوردار باشند.

یکی از مهم‌ترین محدودیت‌های این پژوهش، محدود بودن داده‌ها به اطلاعات مالی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار بود؛ از این رو نتایج ممکن است به سایر شرکت‌ها یا بخش‌های اقتصادی قابل تعمیم کامل نباشد. همچنین مدل‌های مورد استفاده صرفاً بر داده‌های کمی مالی متکی بودند و متغیرهای کیفی مانند کیفیت مدیریت، فرهنگ سازمانی، شرایط سیاسی و تغییرات اقتصادی کلان در تحلیل وارد نشدند. محدودیت دیگر مربوط به عدم توازن داده‌ها میان شرکت‌های ورشکسته و غیرورشکسته بود که اگرچه با استفاده از روش جنگل تصادفی متوازن تا حدی کنترل شد، اما همچنان می‌تواند بر عملکرد مدل تأثیر گذاشته باشد.

پیشنهاد می‌شود پژوهش‌های آینده از الگوریتم‌های پیشرفته‌تر یادگیری عمیق، شبکه‌های عصبی و مدل‌های ترکیبی استفاده کنند تا امکان شناسایی الگوهای پیچیده‌تر فراهم شود. همچنین ترکیب داده‌های صورت‌های مالی با داده‌های متنی شامل اخبار، گزارش‌های تحلیلی، اطلاعات شبکه‌های اجتماعی و شاخص‌های کلان اقتصادی می‌تواند قدرت پیش‌بینی مدل‌ها را افزایش دهد. بررسی نقش عوامل محیط‌زیستی، اجتماعی و حاکمیتی، مقایسه عملکرد الگوریتم‌ها در صنایع مختلف و انجام مطالعات بین‌المللی مقایسه‌ای نیز می‌تواند به توسعه ادبیات پیش‌بینی ورشکستگی کمک کند.

مدیران شرکت‌ها می‌توانند از مدل‌های مبتنی بر هوش مصنوعی به‌عنوان سامانه‌های هشدار زودهنگام برای شناسایی علائم اولیه درماندگی مالی استفاده کنند. سرمایه‌گذاران و تحلیلگران مالی نیز می‌توانند نتایج این مدل‌ها را در کنار تحلیل‌های سنتی برای ارزیابی ریسک سرمایه‌گذاری به کار گیرند. نهادهای ناظر بازار سرمایه نیز می‌توانند با توسعه زیرساخت‌های داده‌محور و به‌کارگیری سامانه‌های هوشمند، نظارت مؤثرتری بر وضعیت مالی شرکت‌ها داشته باشند و از شکل‌گیری بحران‌های گسترده مالی جلوگیری کنند.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تشکر و قدردانی

از تمامی کسانی که در طی مراحل این پژوهش به ما یاری رساندند تشکر و قدردانی می‌گردد.

تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

حمایت مالی

این پژوهش حامی مالی نداشته است.

موازن اخلاقی

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

References

- Abad, P. (2025). A Deeper Theoretical Understanding of the Capital Asset Pricing Model.
- Al-Hafi, K. A. H., Bani-Talebi Dehkordi, B., Al-Mansouri, M. A. A., & Fouladi, M. (2025). Identifying Risk-Dependent Organizational Nodes from a Network Perspective in the Tehran and Iraq Stock Exchanges. *Accounting, Finance and Computational Intelligence*.
- Alshater, M. M. (2026). The Collapse of Credit Suisse: A Case Study in Systemic Failure and State-Brokered Rescue. *Risk management*. <https://doi.org/10.1057/s41283-026-00220-z>
- Asadi, R., Beytari, A., & Ghorbanian, M. R. (2025). Developing a Qualitative Model of Machine Learning and Artificial Intelligence in Activity-Based Project Costing. *Accounting, Finance and Computational Intelligence*, 3(3).
- Asimit, A. V., & Li, J. (2017). Systemic Risk: An Asymptotic Evaluation. *ASTIN Bulletin*. <https://www.semanticscholar.org/paper/cdd8ccb733699e40e5d675a39810b75da7eda8c0>
- Bakir, V., & McStay, A. (2018). Fake News and the Economy of Emotions. *Digital journalism*. <https://www.semanticscholar.org/paper/e546418c674b9c82d3f03da674d2c614541b9e15>
- Clements, A. E., & Liao, Y. (2020). Firm-Specific Information and Systemic Risk. *Economic Modelling*, 90, 480-493. <https://doi.org/10.1016/j.econmod.2019.11.031>
- Curatola, G., Donadelli, M., Kizys, R., & Riedel, M. (2016). Investor Sentiment and Sectoral Stock Returns: Evidence from World Cup Games. *Finance Research Letters*, 17, 267-274. <https://doi.org/10.1016/j.frl.2016.03.023>
- Dalili, A., Azadi Hir, K., & Archin Lisar, M. (2025). Predicting the Occurrence of Negative Stock Returns with Artificial Intelligence Algorithms and Its Relationship with Conservative Reporting in Companies Listed on the Tehran Stock Exchange. *Accounting, Finance and Computational Intelligence*, 3(1).
- Fraz, T. R., Fatima, S., & Radulescu, M. (2026). Financial Forecasting and New Frontiers of Spline-GARCH: A Superiority Analysis over the Traditional GARCH and Machine Learning Models on Belt and Road Initiative Economies. *Risk management*. <https://doi.org/10.1057/s41283-026-00207-w>
- Gao, L., Zhang, H., & Li, Y. (2025). ESG Integration and the Financial Stability Trade-Off in Emerging Markets. *International Journal of Financial Studies*, 14(2), 26. <https://doi.org/10.3390/ijfs14020026>
- Hamidi, A., Ayazi, S., Naderian, A., & Abbasian, H. (2024). Financial Distress Prediction. Third National Conference on New Approaches in Accounting, Auditing and Finance, Aliabad. <https://civilica.com/doc/2284823>
- Jamil, M. (2023). Bankruptcy of Joint-Stock Companies and Its Effects on Shareholders and Company Directors. *Modern Interdisciplinary Legal Research*, 3(2), 62-73.
- Kermani, H. R., & Sadeghi-Manesh, S. (2024). Identifying Components Affecting the Efficiency of Budgeting Based on Artificial Intelligence Algorithms. *Accounting, Finance and Computational Intelligence*, 2(2).
- Khatanlou, M., Siveizi, A., & Kazemi Olum, M. (2025). Corporate Reputation, Risk, and Stock Returns. *Financial Management Perspective*, 14(48), 34-54. <https://doi.org/10.48308/jfmp.2025.237519.1438>
- Mahmoudjanlou, Z., Najafi Moghadam, A., & Latifi Banmaran, M. (2022). Bankruptcy Prediction of Listed Companies Using the DT Algorithm. Fourth International Conference on Management, Accounting, Economics and Banking in the Third Millennium, <https://civilica.com/doc/1601881>
- Memarpour, Z., Askarzadeh Darreh, G. R., Khajeh Mahmoudabadi, H., & Abtahi, S. (2025). Systematic Asset Risk Assessment with a News Analysis Approach in the Tehran Stock Exchange. *Accounting, Finance and Computational Intelligence*, 3(3), 1-16. <https://www.jafci.com/index.php/jafci/article/view/121>
- Pourghaffar, J., & Eghbal Mazraeh, A. (2025). The Relationship between Creative Accounting and Corporate Bankruptcy in Companies Listed on the Tehran Stock Exchange. First National Conference on Professional Ethics and Social Responsibility in Management and Financial Sciences with an Islamic Approach, Urmia. <https://civilica.com/doc/2441573>
- Sharifi, A. (2023). Examining the Role of Artificial Intelligence in Improving Capital Budgeting Decisions from a Computational Perspective. *Accounting, Finance and Computational Intelligence*, 1(2).
- Yang, Z., Wang, Y., & Yuan, X. C. (2026). Disaster Threatens the Investment of Enterprises in China. *Risk management*. <https://doi.org/10.1057/s41283-026-00217-8>