

An Early Warning Credit Risk Prediction Model Based on Metaheuristic Algorithms (Case Study: Bank Sepah)

1. Mohammad Rostami¹: Department of Accounting, Ara.C., Islamic Azad University, Tabriz, Iran

2. Yaghub Pour Karim^{2*}: Department of Accounting, Ta.C., Islamic Azad University, Tabriz, Iran. Email: pourkarim@iaut.ac.ir (Corresponding Author)

3. Younes Badavarnahandi³: Department of Accounting, Ta.C., Islamic Azad University, Tabriz, Iran

4. Rasoul Baradaran Hasanzadeh⁴: Department of Accounting, Ta.C., Islamic Azad University, Tabriz, Iran

5. Mahdi Zeinali⁵: Department of Accounting, Ta.C., Islamic Azad University, Tabriz, Iran

Article history



Received: 22 December 2025

Revised: 29 April 2026

Accepted: 06 May 2026

Initial Publish: 08 June 2026

Final Publish: 22 June 2027

Abstract:

This study aims to develop and validate an intelligent hybrid model for credit risk prediction with early warning capability to support proactive decision-making in banking systems. This data-driven, ex-post facto study was conducted on corporate clients of Bank Sepah. The population included 2,847 firms (2018–2022), from which 340 were selected using proportional stratified sampling. Data were collected from audited financial statements, credit records, and behavioral indicators, and preprocessed through normalization, outlier treatment, and class balancing. Analytical approaches included classical models (logistic regression and Cox survival analysis) and machine learning models (SVM and neural networks). A genetic algorithm was employed for hyperparameter optimization and model aggregation. Model performance was evaluated using accuracy, sensitivity, specificity, F1-score, and AUC. Results indicated that liquidity, profitability, cash flow, and relationship duration significantly reduce default probability and hazard, whereas leverage increases risk. Nonlinear models outperformed linear approaches. The hybrid metaheuristic model achieved the highest AUC and lowest Type II error, demonstrating superior predictive performance and robustness. The survival model also showed strong capability in predicting time-to-default. The proposed framework enhances credit risk prediction accuracy and enables dynamic monitoring and early warning, facilitating more effective and proactive risk management in banking.

Keywords: Credit risk, early warning system, metaheuristic algorithms, machine learning, survival analysis, banking risk management



Extended Abstract**Introduction**

In recent years, the rapid evolution of financial systems, increasing complexity of credit markets, and the growing exposure of banking institutions to systemic and idiosyncratic risks have intensified the need for robust, accurate, and interpretable credit risk assessment models. Credit risk, defined as the probability of a borrower's failure to meet contractual debt obligations, remains one of the most critical determinants of financial stability and institutional sustainability. Traditional statistical approaches, such as logistic regression and discriminant analysis, have long been employed for credit scoring; however, these models often struggle to capture nonlinear relationships, dynamic interactions, and high-dimensional dependencies inherent in modern financial datasets (Arora & Kaur, 2026; Machado et al., 2025). Consequently, the integration of machine learning techniques into credit risk modeling has emerged as a transformative paradigm, enabling more flexible, data-driven, and adaptive predictive systems.

Recent literature highlights the superiority of machine learning algorithms—including support vector machines, random forests, and deep neural networks—in capturing complex patterns within financial data and improving predictive accuracy (Chang et al., 2024; Kurniawan, 2024). Ensemble learning strategies and hybrid models have further enhanced performance by combining multiple algorithms to exploit their complementary strengths (Aruleba & Sun, 2024; Zhu et al., 2022). Additionally, the incorporation of metaheuristic optimization techniques has enabled the fine-tuning of model parameters, thereby improving classification performance and reducing prediction errors (Deng et al., 2025; Paz et al., 2025). Parallel to these advancements, emerging research has emphasized the importance of interpretability and transparency in credit risk models, particularly in regulatory contexts where explainability is essential for accountability and trust (Golec & Alabduljalil, 2026).

Moreover, recent studies have expanded the scope of credit risk analysis by integrating macroeconomic variables, environmental factors, and network-based approaches, reflecting the multifaceted nature of financial risk (Mahadevan et al., 2026; Shao et al., 2026). Graph-based learning models, Bayesian networks, and label propagation techniques have demonstrated potential in modeling dependencies across financial entities and improving predictions in data-scarce environments (Akhmetshin et al., 2026; Gramifar et al., 2026; Peng et al., 2025). Furthermore, temporal modeling approaches, such as survival analysis and Hawkes processes, have underscored the importance of incorporating time dynamics into credit risk evaluation, enabling more accurate estimation of default timing and early warning signals (Lin et al., 2025). These developments collectively suggest that the future of credit risk assessment lies in hybrid, multi-layered models that integrate statistical rigor, computational intelligence, and domain knowledge.

In parallel, optimization techniques inspired by natural and evolutionary processes have been increasingly applied to enhance predictive models. Algorithms such as genetic algorithms, particle swarm optimization, and hybrid metaheuristics have proven effective in optimizing model architectures, feature selection, and decision thresholds (Bao et al., 2024; Purnama et al., 2025). These approaches are particularly valuable in high-dimensional financial contexts, where traditional optimization methods may be insufficient. Additionally, the rise of automated machine learning (AutoML) has facilitated the development of scalable and efficient credit risk systems capable of continuous learning and adaptation (Rajkumar et al., 2025). Taken together, these advancements indicate a shift toward intelligent, adaptive, and integrated frameworks for financial risk management.

Despite these developments, several challenges remain. First, achieving a balance between predictive accuracy and interpretability continues to be a major concern, especially in regulatory environments. Second, many models are evaluated solely on classification accuracy, without considering calibration, economic cost, or decision thresholds. Third, the integration of heterogeneous data sources—including financial, behavioral, and macroeconomic variables—remains methodologically complex. Addressing these gaps requires the development of comprehensive frameworks that not only improve prediction accuracy but also enhance interpretability, robustness, and practical applicability. Therefore, the present study aims to develop and evaluate a hybrid metaheuristic-based model for credit risk prediction, integrating multiple machine learning and statistical approaches to improve accuracy, interpretability, and early warning capabilities.

Methods and Materials

The present study adopted a quantitative, applied research design aimed at developing a hybrid predictive model for credit risk assessment. The dataset consisted of financial, behavioral, and macroeconomic variables collected from corporate clients of a banking institution over a multi-year period. Key variables included liquidity ratios, profitability indicators, leverage ratios, cash flow measures, customer-bank interaction history, and selected macroeconomic indicators such as inflation rate. Data preprocessing involved handling missing values, normalization, and feature scaling to ensure compatibility across models.

Several modeling approaches were employed, including logistic regression, survival analysis, support vector machines (SVM), and group method of data handling (GMDH) neural networks. The SVM model was optimized using a genetic algorithm to determine optimal hyperparameters. The hybrid model was constructed by combining the outputs of individual models using an ensemble framework with optimized weighting. Model performance was evaluated using multiple metrics, including accuracy, area under the ROC curve (AUC), sensitivity, specificity, F1-score, and Brier score for calibration. Additionally, SHAP (Shapley Additive Explanations) analysis was used to assess feature importance and enhance model interpretability. The dataset was divided into training and testing subsets to validate model generalizability.

Findings

The results indicated that all selected financial variables significantly contributed to the prediction of credit risk. Descriptive statistics revealed that firms classified as high-risk exhibited lower liquidity ratios, reduced profitability, weaker cash flow positions, and higher leverage levels compared to low-risk firms. Logistic regression results showed that liquidity, return on assets, and cash flow had negative and statistically significant effects on default probability, whereas leverage had a positive effect. The model achieved an overall accuracy of 76.50% with an AUC of 0.79.

Survival analysis demonstrated that leverage increased the hazard rate of default, while profitability and cash flow reduced the likelihood of early default. The concordance index (C-index) of 0.82 indicated strong predictive ability in ranking default risk over time. The SVM model, optimized via genetic algorithm, significantly outperformed traditional models, achieving an accuracy of 86.30% and an AUC of 0.90. The GMDH neural network further improved performance, with an R^2 value of 0.882 and test accuracy of 88.60%.

The hybrid metaheuristic model demonstrated the highest performance across all metrics, achieving an accuracy of 93.70%, AUC of 0.95, sensitivity of 91.40%, specificity of 95.20%, and F1-score of 0.93. The model reduced type I and type II errors significantly compared to individual models. SHAP analysis identified liquidity ratio, return on assets, leverage, customer interaction history, inflation rate, and cash flow as the most influential variables. The Brier score of 0.048 indicated excellent calibration, confirming that predicted probabilities closely matched actual outcomes.

Discussion and Conclusion

The findings of this study demonstrate that hybrid metaheuristic-based models can significantly enhance the accuracy and reliability of credit risk prediction compared to traditional statistical and standalone machine learning approaches. By integrating multiple modeling techniques, the proposed framework effectively captures both linear and nonlinear relationships, as well as temporal dynamics, thereby providing a more comprehensive representation of credit risk. The superior performance of the hybrid model highlights the importance of combining diverse analytical methods to leverage their complementary strengths.

The inclusion of survival analysis adds a critical temporal dimension to risk assessment, enabling financial institutions not only to identify high-risk clients but also to anticipate the timing of potential default events. This capability is particularly valuable for proactive risk management and early intervention strategies. Furthermore, the application of SHAP analysis enhances model transparency by quantifying the contribution of each variable to the final prediction, thereby addressing concerns related to the interpretability of complex machine learning models.

The results also underscore the significance of integrating macroeconomic variables into credit risk models. Factors such as inflation can influence borrowers' repayment capacity and should be considered in risk assessment frameworks. The strong performance of the hybrid model in both classification and calibration metrics suggests that it can be effectively deployed in real-world banking environments to support decision-making processes, optimize credit allocation, and reduce financial losses.

In conclusion, this study provides empirical evidence supporting the adoption of hybrid, data-driven, and metaheuristically optimized models for credit risk assessment. Such models not only improve predictive accuracy but also enhance interpretability, robustness, and practical applicability. The proposed framework represents a significant step toward the development of intelligent credit risk management systems capable of adapting to the complexities of modern financial environments.

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.

ارائه الگوی پیش‌بینی ریسک اعتباری مبتنی بر هشدار سریع با استفاده از الگوریتم‌های فراابتکاری (مطالعه موردی: بانک سپه)

تاریخچه مقاله



تاریخ دریافت: ۱ دی ۱۴۰۴

تاریخ بازنگری: ۹ اردیبهشت ۱۴۰۵

تاریخ پذیرش: ۱۶ اردیبهشت ۱۴۰۵

تاریخ چاپ اولیه: ۱۸ خرداد ۱۴۰۵

تاریخ چاپ نهایی: ۱ تیر ۱۴۰۶

۱. محمد رستمی*^{id}: گروه حسابداری، واحد بین الملل ارس، دانشگاه آزاد اسلامی، تبریز، ایران

۲. یعقوب پور کریم*^{id}: گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران. ایمیل:

pourkarim@iaut.ac.ir (نویسنده مسئول)

۳. یونس باد اور نهندی^{id}: گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

۴. رسول برادران حسن زاده^{id}: گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

۵. مهدی زینالی^{id}: گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

چکیده

هدف این پژوهش ارائه و اعتبارسنجی یک الگوی ترکیبی و هوشمند برای پیش‌بینی ریسک اعتباری با قابلیت هشدار زودهنگام و تصمیم‌گیری پیش‌دستانه در نظام بانکی است. این پژوهش با رویکرد پس‌رویدادی و داده‌محور بر روی مشتریان حقوقی بانک سپه انجام شد. جامعه آماری شامل ۲۸۴۷ شرکت طی سال‌های ۱۳۹۷ تا ۱۴۰۱ بود که با نمونه‌گیری طبقه‌ای متناسب، ۳۴۰ شرکت انتخاب شدند. داده‌ها از صورت‌های مالی، سوابق اعتباری و اطلاعات رفتاری استخراج و پس از پیش‌پردازش شامل نرمال‌سازی، حذف داده‌های پرت و کنترل عدم توازن آماده‌سازی شدند. برای تحلیل، مدل‌های کلاسیک شامل رگرسیون لجستیک و مدل بقا (کاکس) و مدل‌های یادگیری ماشین شامل SVM و شبکه عصبی به کار رفت. بهینه‌سازی پارامترها و ترکیب مدل‌ها با الگوریتم ژنتیک انجام شد. ارزیابی عملکرد با شاخص‌های دقت، حساسیت، ویژگی، F1 و AUC صورت گرفت. نتایج نشان داد متغیرهای نقدینگی، سودآوری، جریان نقد و سابقه تعامل اثر کاهنده معنادار بر احتمال و زمان نکول دارند، در حالی که اهرم مالی اثر افزایش‌دهنده دارد. مدل‌های غیرخطی عملکرد بهتری نسبت به مدل‌های خطی نشان دادند. مدل ترکیبی فراابتکاری با بیشترین مقدار AUC و کمترین خطای نوع دوم به‌عنوان مدل برتر شناسایی شد و پایداری آن در تحلیل حساسیت تأیید گردید. همچنین مدل بقا قدرت بالایی در پیش‌بینی زمان نکول (C-index) بالا (نشان داد). الگوی پیشنهادی با تلفیق یادگیری ماشین، مدل‌های کلاسیک و بهینه‌سازی فراابتکاری، دقت پیش‌بینی ریسک اعتباری را افزایش داده و امکان پایش پویا و هشدار زودهنگام را برای تصمیم‌گیری مدیریتی فراهم می‌کند.

کلیدواژه‌گان: ریسک اعتباری، هشدار سریع، الگوریتم فراابتکاری، یادگیری ماشین، تحلیل بقا، مدیریت ریسک بانکی

شبهه استناددهی: رستمی، محمد، پور کریم، یعقوب، باد اور نهندی، یونس، برادران حسن زاده، رسول، و زینالی، مهدی. (۱۴۰۶). ارائه الگوی پیش‌بینی ریسک اعتباری مبتنی بر هشدار سریع با استفاده از الگوریتم‌های فراابتکاری (مطالعه موردی: بانک سپه). *حسابداری، امور مالی و هوش محاسباتی*، ۵(۲)، ۲۴-۱.



ریسک اعتباری یکی از بنیادی‌ترین چالش‌های نظام بانکی و مالی معاصر است، زیرا ناتوانی مشتریان در ایفای تعهدات مالی می‌تواند به افزایش مطالبات غیرجاری، کاهش کیفیت دارایی‌ها، تضعیف کفایت سرمایه و در نهایت تهدید ثبات مالی منجر شود. در محیط‌های اقتصادی پیچیده، ارزیابی ریسک اعتباری دیگر نمی‌تواند صرفاً بر تحلیل‌های سنتی، قضاوت کارشناسی یا شاخص‌های مالی ایستا متکی باشد، زیرا رفتار نکول در عمل حاصل تعامل هم‌زمان متغیرهای مالی، رفتاری، نهادی، زمانی و کلان‌اقتصادی است. به همین دلیل، ادبیات نوین اعتبارسنجی به تدریج از مدل‌های خطی و تک‌بعدی فاصله گرفته و به سوی مدل‌های داده‌محور، یادگیری ماشین، یادگیری عمیق، مدل‌های ترکیبی و سامانه‌های هشدار سریع حرکت کرده است (Arora & Kaur, 2026; Aruleba & Sun, 2024; Gramifar et al., 2026). چنین تحولی نشان می‌دهد که مدیریت ریسک اعتباری نه تنها یک فعالیت پسینی برای تشخیص مشتریان مسئله‌دار، بلکه یک فرایند پیش‌نگر برای شناسایی زود هنگام سیگنال‌های بحران و مداخله پیش‌دستانه است. اهمیت این مسئله در نظام بانکی زمانی برجسته‌تر می‌شود که بانک‌ها با حجم گسترده داده‌های مالی و غیرمالی، مشتریان ناهمگون، شرایط تورمی، شوک‌های کلان، تغییرات بازار و فشارهای مقرراتی مواجه باشند؛ در چنین بستری، طراحی الگوهای پیش‌بینی دقیق، پایدار، تفسیرپذیر و قابل اجرا برای تصمیم‌گیری اعتباری ضرورتی راهبردی محسوب می‌شود.

در سطح نظری، ریسک اعتباری را می‌توان بازتابی از عدم قطعیت در رفتار بازپرداخت و توان مالی مشتری دانست. مدل‌های کلاسیک، مانند رگرسیون لجستیک و مدل‌های امتیازدهی اعتباری، معمولاً بر فرض خطی بودن روابط، استقلال نسبی متغیرها و امکان تبیین احتمال نکول بر اساس مجموعه‌ای محدود از شاخص‌ها استوارند. با وجود کارکرد ارزشمند این مدل‌ها در ساده‌سازی و تفسیر تصمیم‌های اعتباری، شواهد جدید نشان می‌دهد که روابط میان شاخص‌های مالی و نکول اغلب غیرخطی، وابسته به زمان و متأثر از تعاملات پنهان میان متغیرهاست. برای نمونه، مدل‌های مبتنی بر فرایند هاوکس نشان داده‌اند که رخدادهای اعتباری می‌توانند دارای الگوی خوشه‌ای و وابستگی زمانی باشند و بنابراین نکول‌ها لزوماً رویدادهایی مستقل و پراکنده نیستند (Lin et al., 2025). این دیدگاه با ضرورت بهره‌گیری از مدل‌های زمان‌محور، از جمله تحلیل بقا، همسو است؛ زیرا بانک‌ها فقط به دانستن احتمال نکول نیاز ندارند، بلکه باید بدانند نکول در چه افق زمانی محتمل‌تر است و چه زمانی باید مداخله مدیریتی انجام شود.

تحول مهم دیگر در ادبیات ریسک اعتباری، گسترش رویکردهای یادگیری ماشین و یادگیری عمیق است. این رویکردها، برخلاف مدل‌های سنتی، قادرند روابط غیرخطی، تعاملات چندگانه، الگوهای پیچیده و ساختارهای پنهان در داده‌ها را شناسایی کنند. مطالعات اخیر نشان داده‌اند که الگوریتم‌هایی مانند جنگل تصادفی، XGBoost، ماشین بردار پشتیبان، شبکه‌های عصبی و مدل‌های یادگیری عمیق در بسیاری از موارد عملکردی برتر از مدل‌های کلاسیک دارند و می‌توانند دقت پیش‌بینی نکول را افزایش دهند (Chang et al., 2024; Kurniawan, 2024). در همین راستا، تحلیل‌های علم‌سنجی حوزه هوش مصنوعی و ریسک اعتباری نشان می‌دهند که ادغام هوش مصنوعی از ارزیابی اعتباری به یکی از مرزهای اصلی پژوهش‌های مالی تبدیل شده است و تمرکز پژوهش‌ها به سمت مدل‌های هوشمند، داده‌های چندمنبعی، قابلیت تفسیر و کاربردهای عملی در تصمیم‌گیری اعتباری حرکت کرده است (Arora & Kaur, 2026). بنابراین، اعتبارسنجی نوین نه صرفاً یک مسئله آماری، بلکه یک مسئله هوش تصمیم‌گیری است که نیازمند تلفیق دقت پیش‌بینی، تفسیرپذیری و قابلیت پیاده‌سازی عملیاتی است.

با وجود عملکرد بالای بسیاری از مدل‌های یادگیری ماشین، یک چالش اساسی همچنان باقی است: هیچ الگوریتم منفردی نمی‌تواند تمام ابعاد ریسک اعتباری را به‌طور کامل پوشش دهد. مدل‌های خطی تفسیرپذیر اما محدودند، مدل‌های غیرخطی دقیق‌تر اما گاهی کم‌تفسیرند، مدل‌های مبتنی بر زمان بُعد پویایی نکول را آشکار می‌کنند، و شبکه‌های عصبی قادر به کشف ساختارهای عمیق ولی دارای هزینه محاسباتی بالاتر هستند. به همین دلیل، رویکردهای تجمیعی و ترکیبی اهمیت فزاینده‌ای یافته‌اند. پژوهش‌ها نشان داده‌اند که ترکیب چند طبقه‌بند پایه در قالب مدل‌های Ensemble یا Stacking می‌تواند با بهره‌گیری از تنوع خطاها، عملکرد کلی را بهبود دهد و پایداری پیش‌بینی را افزایش دهد (Zhu et al., 2022). همچنین استفاده از طبقه‌بند‌های تجمیعی همراه با توضیح‌پذیری مدل، علاوه بر افزایش دقت، امکان فهم منطق تصمیم‌گیری را نیز فراهم می‌کند و این امر برای محیط‌های بانکی که نیازمند پاسخ‌گویی، شفافیت و قابلیت دفاع از تصمیم هستند اهمیت دارد (Aruleba & Sun, 2024). بنابراین، مدل ترکیبی می‌تواند راهی برای عبور از محدودیت‌های الگوریتم‌های منفرد و ایجاد چارچوبی چندبعدی برای ارزیابی ریسک اعتباری باشد.

در کنار یادگیری ماشین، الگوریتم‌های فراابتکاری جایگاه مهمی در بهینه‌سازی مدل‌های پیش‌بینی پیدا کرده‌اند. مسئله اعتبارسنجی معمولاً شامل انتخاب ویژگی‌ها، تنظیم ابرپارامترها، تعیین آستانه‌های تصمیم، وزن‌دهی به مدل‌های پایه و کاهش خطای پیش‌بینی است؛ این مسائل اغلب دارای فضای جستجوی پیچیده و غیرخطی هستند و روش‌های کلاسیک بهینه‌سازی ممکن است در بهینه‌های محلی گرفتار شوند. الگوریتم‌های فراابتکاری مانند الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و سایر روش‌های الهام‌گرفته از طبیعت، امکان جستجوی سراسری و یافتن ترکیب‌های بهینه را فراهم می‌کنند. مرور نظام‌مند مطالعات نشان داده است که ترکیب یادگیری ماشین و فراابتکاری‌ها در ارزیابی فردی ریسک اعتباری، به‌ویژه در انتخاب ویژگی و تنظیم پارامترها، می‌تواند دقت و پایداری مدل‌ها را ارتقا دهد (Paz et al., 2025). همچنین، کاربرد XGBoost همراه با بهینه‌سازی فراابتکاری در پیش‌بینی تأیید اعتباری نشان داده است که چنین رویکردی می‌تواند ریسک تصمیم‌گیری را کاهش دهد و کیفیت طبقه‌بندی مشتریان را افزایش دهد (Deng et al., 2025). بر همین اساس، استفاده از الگوریتم ژنتیک برای تنظیم وزن مدل‌های پایه و تولید یک امتیاز نهایی ریسک می‌تواند روشی مناسب برای طراحی سامانه‌ای دقیق‌تر و پایدارتر باشد.

در حوزه مدل‌های خاص، ترکیب ماشین بردار پشتیبان با الگوریتم ژنتیک در مدیریت ریسک اعتباری زنجیره تأمین مالی نشان داده است که بهینه‌سازی پارامترهای SVM می‌تواند توان تفکیک مدل را بهبود بخشد و مرزهای تصمیم‌گیری دقیق‌تری ایجاد کند (Bao et al., 2024). همچنین، استفاده از مدل‌های مبتنی بر یادگیری تجمعی و یادگیری عمیق همراه با نظریه تصمیم‌گیری سه‌گانه نشان داده است که می‌توان از تصمیم‌گیری دوحالته ساده عبور کرد و وضعیت‌های مرزی یا نامطمئن را به‌صورت انعطاف‌پذیرتر مدیریت نمود (Li et al., 2026). این موضوع برای نظام بانکی اهمیت بالایی دارد، زیرا بسیاری از مشتریان نه کاملاً سالم و نه کاملاً پرریسک هستند، بلکه در وضعیت‌های انتقالی قرار دارند و نیازمند پایش، بازنگری شرایط یا اقدامات پیشگیرانه‌اند. از سوی دیگر، مدل‌های مبتنی بر سود و آستانه‌های بهینه تصمیم‌گیری نشان می‌دهند که پیش‌بینی ریسک اعتباری باید صرفاً به حداکثرسازی دقت محدود نشود، بلکه باید پیامد اقتصادی تصمیم‌های اعتباری و سودآوری وام‌دهی نیز در نظر گرفته شود (Li et al., 2024). بنابراین، ارزیابی مدل‌های اعتباری باید هم‌زمان بر معیارهای آماری و پیامدهای مالی متمرکز باشد.

بعد دیگری که در ریسک اعتباری معاصر اهمیت یافته، ساختار شبکه‌ای و سیستمی ریسک است. بنگاه‌ها و مشتریان بانکی در خلأ فعالیت نمی‌کنند، بلکه در شبکه‌ای از روابط تجاری، اعتباری، زنجیره تأمین، بازار و تعاملات مالی قرار دارند. در چنین شرایطی، ریسک می‌تواند از طریق پیوندهای شبکه‌ای منتقل یا تشدید شود. مدل‌های گرافی و شبکه‌های پیچیده در ارزیابی ریسک اعتباری با داده‌های برجسب‌دار محدود نشان داده‌اند که استفاده از الگوریتم انتشار برجسب و رویکردهای شبکه‌ای می‌تواند ارزیابی ریسک را در شرایط کمبود داده بهبود بخشد (Peng et al., 2025). همچنین، شبکه‌های کانولوشنی گرافی در پیش‌بینی ریسک اعتباری مالی توانسته‌اند روابط غیرخطی و ساختارهای ارتباطی پیچیده را شناسایی کنند و از این طریق به تحلیل پایدار اقتصادی کمک نمایند (Akhmetshin et al., 2026). افزون بر این، ترکیب شبکه‌های بیزی و یادگیری ماشین در ارزیابی ریسک اعتباری نشان داده است که می‌توان هم دقت پیش‌بینی و هم قابلیت تفسیر وابستگی‌های احتمالی و علی میان متغیرها را افزایش داد (Gramifar et al., 2026). این مطالعات اهمیت حرکت از مدل‌های منفرد مشتری‌محور به مدل‌های چندبعدی، شبکه‌ای و ساختاری را برجسته می‌کنند.

در سال‌های اخیر، تفسیرپذیری مدل‌ها نیز به یکی از دغدغه‌های اصلی اعتبارسنجی تبدیل شده است. مدل‌های پیچیده اگرچه ممکن است دقت بالایی داشته باشند، اما اگر منطق تصمیم آن‌ها برای مدیران، ناظران و مشتریان قابل توضیح نباشد، پذیرش عملیاتی و مقرراتی آن‌ها با چالش مواجه می‌شود. مرور نظام‌مند مدل‌های زبانی بزرگ تفسیرپذیر در ریسک اعتباری نشان داده است که آینده ارزیابی اعتباری به سمت ترکیب مدل‌های پیشرفته با سازوکارهای توضیح‌پذیر حرکت می‌کند (Golec & Alabduljalil, 2026). این نکته با ضرورت استفاده از روش‌هایی مانند SHAP، تحلیل اهمیت متغیرها و کالیبراسیون احتمال‌ها در مدل‌های اعتباری همخوان است. در نظام بانکی، تفسیرپذیری فقط یک ویژگی فنی نیست، بلکه شرطی برای پاسخ‌گویی، کنترل سوگیری، رعایت الزامات نظارتی و اعتماد مدیران اعتباری به خروجی مدل است.

ریسک اعتباری علاوه بر شاخص‌های مالی درون‌شرکتی، به‌شدت تحت تأثیر عوامل محیطی و کلان نیز قرار دارد. تحول اقلیمی، ریسک انتقال، ساختار پرتفوی انرژی و تمرکز اعتباری در صنایع کربن‌بر از جمله عواملی هستند که به‌تدریج وارد تحلیل ریسک بانکی شده‌اند. پژوهش‌ها نشان داده‌اند که تمرکز کربنی در پرتفوی بانک‌ها می‌تواند از مسیر افزایش ریسک اعتباری و کاهش کارایی بانکی اثرگذار باشد و سرمایه بانک نقش مهمی در تعدیل این رابطه دارد (Mahadevan et al., 2026). همچنین، تسهیلات اعطایی

به صنایع سوخت فسیلی می‌تواند از طریق افزایش ذخایر زیان اعتباری مورد انتظار و الزامات سرمایه‌ای، ریسک انتقال را برای بانک‌ها تشدید کند (Shao et al., 2026). در مقابل، توسعه انرژی‌های تجدیدپذیر می‌تواند از طریق تقویت رشد اقتصادی، اثر کاهنده بر ریسک اعتباری بانک‌ها داشته باشد (Plikas & Kenourgios, 2026). این یافته‌ها نشان می‌دهد که مدل‌های پیش‌بینی ریسک اعتباری باید علاوه بر متغیرهای مالی شرکت‌ها، متغیرهای کلان، محیطی و ساختاری را نیز در نظر بگیرند تا بتوانند تصویری واقعی‌تر از ریسک ارائه دهند.

در کنار ریسک‌های مالی و محیطی، تحول دیجیتال، امنیت سایبری و اتوماسیون نیز بر مدیریت ریسک بانکی اثرگذار شده‌اند. مدل‌های خودکار یادگیری ماشین برای پیش‌بینی ریسک مالی و پایش بانکی در چارچوب امنیت سایبری نشان می‌دهند که بانک‌ها با داده‌های بسیار متنوعی مواجه‌اند و استفاده از روش‌های خودکار می‌تواند استخراج الگوهای پنهان و پایش مستمر را تقویت کند (Rajkumar et al., 2025). این مسئله به‌ویژه در سامانه‌های هشدار سریع اهمیت دارد، زیرا هدف چنین سامانه‌هایی تشخیص زودهنگام تغییرات خطرناک در وضعیت مشتری است. تجربه مدل‌های هشدار سریع در حوزه‌های دیگر، مانند پیش‌بینی و بهینه‌سازی هشدار سونامی با ترکیب یادگیری عمیق و الگوریتم‌های فراابتکاری، نشان داده است که تلفیق پیش‌بینی هوشمند با بهینه‌سازی می‌تواند توان تشخیص زودهنگام رخداد‌های پرخطر را بهبود دهد (Purnama et al., 2025). اگرچه زمینه کاربرد متفاوت است، منطق روش‌شناختی آن برای ریسک اعتباری نیز قابل توجه است: شناسایی زودهنگام سیگنال‌ها، بهینه‌سازی تصمیم و کاهش خسارت پیش از وقوع بحران.

از منظر روش‌شناختی، طراحی یک مدل هشدار سریع اعتباری باید چند ویژگی کلیدی داشته باشد. نخست، باید بتواند احتمال نکول را بر اساس داده‌های مالی، رفتاری و محیطی برآورد کند. دوم، باید بعد زمانی ریسک را تحلیل کند و مشخص نماید که نکول در چه بازه‌ای محتمل‌تر است. سوم، باید روابط غیرخطی و تعاملات پیچیده میان متغیرها را تشخیص دهد. چهارم، باید خروجی‌های خود را به‌صورت قابل تفسیر ارائه کند تا مدیران بتوانند مبنای تصمیم را درک کنند. پنجم، باید امکان تنظیم آستانه‌ها، رتبه‌بندی مشتریان، تعریف سناریوهای هشدار و پیشنهاد اقدامات مدیریتی را فراهم سازد. رویکردهای ترکیبی مبتنی بر مدل‌های چندگانه و بهینه‌سازی فراابتکاری می‌تواند این الزامات را بهتر از مدل‌های منفرد پوشش دهند. حتی در حوزه‌های غیرمالی مانند پیش‌بینی ریسک قلبی-عروقی نیز تلفیق SVM، منطق فازی و انتگرال سوگنو نشان داده است که ترکیب مدل‌های مختلف می‌تواند ظرفیت پیش‌بینی و تصمیم‌گیری را در مسائل پیچیده افزایش دهد (Kunjachen & Kavitha, 2025). بنابراین، منطق ترکیب مدل‌ها فراتر از یک حوزه خاص است و در مسائل پریسک، چندبعدی و غیرخطی کاربرد گسترده دارد.

با توجه به مباحث فوق، شکاف اصلی در بسیاری از مدل‌های موجود آن است که یا بر دقت پیش‌بینی تمرکز می‌کنند اما تفسیرپذیری و کاربرد مدیریتی محدودی دارند، یا فقط یک الگوریتم منفرد را بهینه می‌کنند و از ظرفیت تلفیق ابعاد مختلف ریسک استفاده نمی‌کنند، یا احتمال نکول را پیش‌بینی می‌کنند اما زمان وقوع و سناریوهای مداخله را در نظر نمی‌گیرند. افزون بر این، بسیاری از مدل‌ها بر شاخص‌های آماری مانند دقت و AUC تمرکز دارند و پیامدهای اقتصادی خطاهای نوع اول و دوم، کاهش مطالبات معوق، بهبود پرتفوی اعتباری و بازگشت سرمایه پیاده‌سازی را کمتر تحلیل می‌کنند. از این رو، یک الگوی کارآمد برای نظام بانکی باید بتواند مدل‌های کلاسیک، تحلیل بقاء، یادگیری ماشین، شبکه عصبی خودسازمانده و الگوریتم ژنتیک را در قالب یک سامانه هشدار سریع ترکیب کند و خروجی آن به‌صورت امتیاز ریسک، سطح هشدار و اقدام مدیریتی قابل استفاده باشد. بر این اساس، پژوهش حاضر با تمرکز بر بانک سپه در پی طراحی و اعتبارسنجی الگویی برای پیش‌بینی ریسک اعتباری مبتنی بر هشدار سریع است که در آن، مدل لاجیت، تحلیل بقاء، ماشین بردار پشتیبان بهینه‌شده، شبکه عصبی GMDH و الگوریتم ژنتیک به‌صورت یکپارچه به کار گرفته می‌شوند. نوآوری این پژوهش در چند سطح قابل طرح است: نخست، ترکیب مدل‌های کلاسیک و هوشمند برای پوشش ابعاد احتمالاتی، زمانی، غیرخطی و ساختاری ریسک؛ دوم، استفاده از الگوریتم فراابتکاری برای بهینه‌سازی وزن مدل‌ها و تولید امتیاز نهایی ریسک؛ سوم، طراحی سناریوهای هشدار زرد، نارنجی و قرمز برای تبدیل خروجی آماری به اقدام مدیریتی؛ چهارم، تحلیل تفسیرپذیری و اهمیت متغیرها برای افزایش شفافیت تصمیم؛ و پنجم، ارزیابی پیامدهای اقتصادی مدل در کاهش خطا، بهبود پرتفوی و کاهش مطالبات معوق. هدف این پژوهش ارائه الگوی پیش‌بینی ریسک اعتباری مبتنی بر هشدار سریع با استفاده از الگوریتم فراابتکاری در بانک سپه است.

روش پژوهش و مواد

این پژوهش با رویکردی داده‌محور و از نوع پس‌رویدادی، به طراحی و اعتبارسنجی الگوی پیش‌بینی ریسک اعتباری مبتنی بر هشدار سریع در بانک سپه می‌پردازد. جامعه آماری این بخش شامل کلیه مشتریان حقوقی بانک سپه در بازه زمانی ۱۳۹۷ تا ۱۴۰۱ است که دارای شرایط ورود به مطالعه باشند. این شرایط شامل برخورداری از حداقل یک تسهیلات اعتباری بیش از ۱۰ میلیارد ریال، داشتن حداقل سه سال سابقه تعامل مستمر با بانک، دسترسی به اطلاعات مالی کامل شامل ترازنامه، صورت سود و زیان و صورت جریان وجوه نقد، و نداشتن سوابق کیفی مرتبط با تقلب مالی یا ورشکستگی تقلبی است. بر اساس آمار رسمی، حجم جامعه آماری برابر با ۲۸۴۷ شرکت حقوقی بوده است. با توجه به ناهمگونی جامعه و وجود طبقات مختلف اعتباری، در این بخش از روش نمونه‌گیری طبقه‌ای متناسب استفاده شده است. جامعه مورد مطالعه بر اساس وضعیت اعتباری به پنج طبقه شامل خوش حساب، سررسید گذشته، معوق، مشکوک‌الوصول و نکول تقسیم شد و سپس نمونه‌ها متناسب با سهم هر طبقه در جامعه انتخاب شدند. حجم نمونه با استفاده از فرمول کوکران برای جامعه محدود و با در نظر گرفتن سطح اطمینان ۹۵ درصد، خطای مجاز ۰/۰۵ و حداکثر پراکندگی، ۳۴۰ شرکت برآورد شد. پس از تعیین حجم نمونه، انتخاب واحدها در هر طبقه به روش تصادفی ساده انجام گرفت تا نمایندگی مناسب هر طبقه در نمونه حفظ شود. داده‌های مورد نیاز این بخش از پایگاه اطلاعاتی پرونده‌های اعتباری مشتریان حقوقی بانک سپه استخراج شد. این داده‌ها شامل اطلاعات مالی، شاخص‌های رفتاری، سوابق بازپرداخت، وضعیت طبقه‌بندی اعتباری و سایر متغیرهای مرتبط با ریسک اعتباری بود. پس از استخراج داده‌ها و با رعایت الزامات محرمانگی، فرایند آماده‌سازی و پیش‌پردازش داده‌ها آغاز شد. این مرحله شامل پاک‌سازی داده‌ها، بررسی و مدیریت مقادیر گمشده، شناسایی و کنترل داده‌های پرت، یکسان‌سازی واحدها، استانداردسازی قالب متغیرها، نرمال‌سازی متغیرها، کنترل عدم توازن طبقات اعتباری و آماده‌سازی متغیر وابسته بود. متغیر وابسته در این پژوهش وضعیت اعتباری مشتری یا احتمال نکول در نظر گرفته شد. برای تحلیل داده‌ها، ابتدا آمار توصیفی با هدف شناخت ویژگی‌های اولیه داده‌ها و مقایسه طبقات اعتباری استخراج شد. در این مرحله شاخص‌هایی مانند فراوانی، درصد فراوانی، میانگین، انحراف معیار و جداول توصیفی مورد استفاده قرار گرفت. در ادامه، به منظور مدل‌سازی و پیش‌بینی ریسک اعتباری، چند مدل به صورت موازی توسعه یافت. این مدل‌ها شامل رگرسیون لجستیک چندگانه به عنوان مدل خط مبنا، تحلیل بقا برای بررسی پویایی زمان وقوع نکول، ماشین بردار پشتیبان و شبکه عصبی مصنوعی به عنوان روش‌های یادگیری ماشین برای شناسایی روابط پیچیده و غیرخطی میان متغیرها بودند. به منظور افزایش دقت پیش‌بینی و دستیابی به یک مدل بهینه، از الگوریتم ژنتیک به عنوان الگوریتم فراابتکاری استفاده شد. نقش این الگوریتم در پژوهش حاضر شامل انتخاب بهینه ویژگی‌ها، تنظیم پارامترها و ابرپارامترهای مدل‌ها، بهینه‌سازی ساختار مدل‌ها و تعیین آستانه‌های مناسب برای تولید هشدار سریع بود. در نهایت، خروجی مدل‌های پایه در قالب یک چارچوب ترکیبی تجمیع شد و مدل فراابتکاری محقق‌ساخته برای پیش‌بینی ریسک اعتباری ارائه گردید. برای ارزیابی عملکرد مدل‌ها، داده‌ها به دو بخش آموزش و آزمون تقسیم شدند؛ به طوری که ۷۰ درصد داده‌ها برای آموزش مدل‌ها و ۳۰ درصد برای آزمون و ارزیابی نهایی مورد استفاده قرار گرفت. مقایسه عملکرد مدل‌ها بر اساس شاخص‌های دقت، حساسیت، ویژگی، امتیاز F_1 و سطح زیر منحنی ROC انجام شد. در پایان، مدلی به عنوان مدل منتخب معرفی شد که علاوه بر برخورداری از قدرت پیش‌بینی بالاتر، توانایی بیشتری در تفکیک مشتریان پرریسک و تولید سیگنال‌های هشدار سریع برای مداخله پیش‌دستانه مدیریتی داشته باشد.

یافته‌ها

برای هر متغیر، شاخص‌های مرکزی و پراکندگی محاسبه شد و وضعیت توزیع متغیرها با آزمون کولموگروف-اسمیرنوف بررسی گردید. شاخص‌های توصیفی بر اساس روابط زیر محاسبه شدند: میانگین $= \sum x_i / n$ ، انحراف معیار $= \sqrt{[\sum (x_i - \bar{x})^2 / (n - 1)]}$ ، چولگی $= E[(X - \mu)^3] / \sigma^3$ و کشیدگی $= E[(X - \mu)^4] / \sigma^4 - 3$. نتایج نشان داد نسبت جاری و جریان نقد عملیاتی از توزیعی نزدیک به نرمال برخوردار بودند، اما نسبت بدهی به حقوق صاحبان سهام و بازده دارایی‌ها از نرمالیتی انحراف معنادار داشتند.

جدول ۱. آمار توصیفی و وضعیت توزیع متغیرهای کمی

متغیر	میانگین	انحراف معیار	حداقل	حداکثر	چولگی	کشیدگی	وضعیت توزیع
نسبت جاری	۱.۳۲	۰.۴۸	۰.۶۷	۲.۸۹	۰.۸۲	۰.۳۴	نرمال، $p = ۰.۱۲$
نسبت بدهی به حقوق صاحبان سهام	۰.۸۵	۰.۳۲	۰.۱۲	۲.۴۵	۱.۱۵	۰.۶۷	چوله راست، $p < ۰.۰۰۱$
بازده دارایی‌ها، ROA (%)	۸.۷۰	۴.۲۰	-۵.۳۰	۲۲.۱۰	-۰.۹۳	۱.۲۸	چوله چپ، $p < ۰.۰۰۱$
جریان نقد عملیاتی، میلیارد ریال	۱۲.۴۰	۸.۹۰	-۳.۲۰	۴۵.۶۰	۰.۷۶	۰.۵۴	نرمال، $p = ۰.۰۰۸$

نسبت جاری با میانگین ۱.۳۲ و انحراف معیار ۰.۴۸ نشان داد که شرکت‌های مورد مطالعه به طور متوسط از سطحی نسبتاً قابل قبول از نقدینگی کوتاه‌مدت برخوردار بودند. حداقل ۰.۶۷ و حداکثر ۲.۸۹ بیانگر ناهمگنی در توان پوشش بدهی‌های جاری است. با وجود چولگی مثبت ۰.۸۲، آزمون کولموگروف-اسمیرنوف با مقدار $p = 0.12$ فرض نرمال بودن این متغیر را رد نکرد. در مقابل، نسبت بدهی به حقوق صاحبان سهام با میانگین ۰.۸۵ و چولگی ۱.۱۵ دارای توزیع چوله راست بود و معناداری آزمون نرمالیتی آن در سطح $p < 0.01$ نشان داد که بخشی از شرکت‌ها دارای اهرم مالی بسیار بالا هستند. بازده دارایی‌ها با میانگین ۸.۷۰ درصد نشان‌دهنده سودآوری مثبت کلی نمونه بود، اما دامنه گسترده آن از -۵.۳۰ تا ۲۲.۱۰ درصد و چولگی منفی -۰.۹۳ بیانگر وجود شرکت‌های زیان‌ده یا دارای عملکرد ضعیف در انتهای چپ توزیع بود. جریان نقد عملیاتی نیز با میانگین ۱۲.۴۰ میلیارد ریال و انحراف معیار ۸.۹۰ میلیارد ریال نشان‌دهنده پراکندگی قابل توجه در توان تولید نقدینگی بود، با این حال مقدار $p = 0.08$ بیانگر عدم رد فرض نرمالیتی بود. در مجموع، یافته‌های توصیفی نشان داد متغیرهای مرتبط با ساختار سرمایه و سودآوری بیش از متغیرهای نقدینگی در معرض ناهمگنی و داده‌های حدی قرار دارند. برای مقایسه شاخص‌های مالی در طبقات مختلف کیفیت اعتباری، از تحلیل واریانس یک‌طرفه استفاده شد. نتایج نشان داد میانگین همه شاخص‌ها در پنج طبقه اعتباری تفاوت معنادار دارد.

جدول ۲. مقایسه شاخص‌های مالی در طبقات اعتباری

متغیر	خوش حساب	سررسید گذشته	معوق	مشکوک‌الوصول	نکول	p-value
نسبت جاری	۱.۶۷	۱.۴۲	۱.۱۵	۰.۹۲	۰.۷۳	< ۰.۰۰۱
نسبت بدهی به حقوق صاحبان سهام	۰.۶۲	۰.۷۸	۱.۰۵	۱.۳۸	۱.۸۷	< ۰.۰۰۱
ROA (%)	۱۲.۴۰	۹.۸۰	۶.۲۰	۲.۱۰	-۳.۵۰	< ۰.۰۰۱
جریان نقد عملیاتی، میلیارد ریال	۱۸.۶۰	۱۲.۳۰	۷.۸۰	۲.۴۰	-۱.۲۰	< ۰.۰۰۱

نتایج تحلیل واریانس یک‌طرفه نشان داد که میانگین شاخص‌های مالی در تمام طبقات اعتباری تفاوت معنادار دارد؛ به‌گونه‌ای که مقدار p برای همه متغیرها کمتر از ۰.۰۰۱ بود. با حرکت از طبقه خوش‌حساب به سمت نکول، نسبت جاری از ۱.۶۷ به ۰.۷۳ کاهش یافت که نشان‌دهنده تضعیف تدریجی توان نقدینگی و سرمایه در گردش است. نسبت بدهی به حقوق صاحبان سهام از ۰.۶۲ به ۱.۸۷ افزایش یافت که بیانگر رشد شدید اهرم مالی و وابستگی بیشتر شرکت‌های نکول کرده به منابع بدهی است. بازده دارایی‌ها از ۱۲.۴۰ درصد در گروه خوش‌حساب به -۳.۵۰ درصد در گروه نکول کاهش یافت و جریان نقد عملیاتی نیز از ۱۸.۶۰ میلیارد ریال به -۱.۲۰ میلیارد ریال رسید. بنابراین، وخامت وضعیت اعتباری با کاهش نقدینگی، افزایش اهرم مالی، افت سودآوری و تخریب جریان نقدی همراه بود. این الگوی مرحله‌ای نشان می‌دهد که متغیرهای منتخب می‌توانند به‌عنوان شاخص‌های کلیدی در مدل‌های رتبه‌بندی اعتباری، سیستم‌های هشدار زود هنگام و چارچوب‌های مدیریت ریسک بانکی به کار گرفته شوند.

مدل لاجیت چندگانه به‌عنوان مدل پایه اقتصادسنجی برای پیش‌بینی وضعیت اعتباری چندرده‌ای استفاده شد. متغیر وابسته شامل پنج طبقه اعتباری خوش‌حساب، سررسید گذشته، معوق، مشکوک‌الوصول و نکول بود. متغیرهای کمی با روش Z-Score نرمال‌سازی شدند، متغیرهای کیفی به متغیرهای مجازی تبدیل شدند و داده‌های پرت با روش IQR کنترل گردیدند؛ در این مرحله فقط ۳.۲۰ درصد داده‌ها حذف شدند. انتخاب متغیر با روش گام‌به‌گام رو به عقب و آستانه $p < 0.05$ انجام شد و هم‌خطی با شاخص VIF بررسی گردید که همه مقادیر آن کمتر از ۵ بود. مدل با حداکثر درست‌نمایی برآورد شد و خطاهای استاندارد با روش سندویچ محاسبه شدند. فرم کلی مدل به‌صورت زیر بود:

$$\ln[P(Y = j) / P(Y = \text{reference})] = \beta_{0j} + \beta_{1j}X_1 + \beta_{2j}X_2 + \dots + \beta_{kj}X_k$$

نسبت شانس نیز از رابطه زیر محاسبه شد:

$$\text{Odds Ratio} = \text{Exp}(\beta)$$

جدول ۳. نتایج مدل لاجیت چندگانه و شاخص‌های برازش

متغیر	ضریب β	خطای استاندارد	آماره Z	p-value	Exp(β)	فاصله اطمینان ۹۵٪
نسبت جاری	-۰.۸۲	۰.۲۴	-۳.۴۲	۰.۰۰۳	۰.۴۴	[۰.۲۸, ۰.۶۹]
ROA (%)	-۰.۶۴	۰.۱۹	-۳.۳۷	۰.۰۰۸	۰.۵۳	[۰.۳۶, ۰.۷۷]
سابقه تعامل، سال	-۱.۲۱	۰.۳۱	-۳.۹۰	۰.۰۰۱	۰.۳۰	[۰.۱۶, ۰.۵۶]
نسبت بدهی به حقوق صاحبان سهام	۰.۷۳	۰.۲۸	۲.۶۱	۰.۰۱۲	۲.۰۸	[۱.۲۰, ۳.۶۰]
جریان نقد عملیاتی	-۰.۵۱	۰.۲۲	-۲.۳۲	۰.۰۲۴	۰.۶۰	[۰.۳۹, ۰.۹۳]
ثابت مدل	۲.۴۵	۰.۶۷	۳.۶۶	۰.۰۰۱	—	—
دقت کلی مدل	۷۶.۵۰٪	—	—	—	—	—
Log Likelihood	-۱۸۷.۳۲	—	—	—	—	—
آزمون نسبت درست‌نمایی	$\chi^2(5) = ۸۹.۴۷$	—	—	< ۰.۰۰۱	—	—
Cox & Snell R ²	۰.۲۸	—	—	—	—	—
Nagelkerke R ²	۰.۳۵	—	—	—	—	—
Hosmer-Lemeshow	$\chi^2(8) = ۱۲.۳۴$	—	—	۰.۱۳۶	—	برازش مناسب

نتایج مدل لاجیت نشان داد همه متغیرهای مالی و رابطه‌ای وارد شده در مدل در سطح کمتر از ۰.۰۵ معنادار بودند. نسبت جاری اثر منفی و معنادار بر احتمال نکول داشت؛ نسبت شانس ۰.۴۴ نشان داد که هر واحد افزایش در نسبت جاری، شانس نکول را حدود ۵۶ درصد کاهش می‌دهد. ROA نیز اثر کاهنده داشت و نسبت شانس ۰.۵۳ نشان داد که افزایش سودآوری احتمال نکول را حدود ۴۷ درصد کاهش می‌دهد. سابقه تعامل با بانک قوی‌ترین اثر محافظتی را نشان داد؛ به‌گونه‌ای که هر سال افزایش در سابقه تعامل، شانس نکول را حدود ۷۰ درصد کاهش داد. در مقابل، نسبت بدهی به حقوق صاحبان سهام با ضریب مثبت ۰.۷۳ و نسبت شانس ۲.۰۸ نشان داد که هر واحد افزایش در اهرم مالی، شانس نکول را بیش از دو برابر می‌کند. جریان نقد عملیاتی نیز با نسبت شانس ۰.۶۰ نشان داد که افزایش جریان نقد، احتمال نکول را حدود ۴۰ درصد کاهش می‌دهد. دقت کلی مدل ۷۶.۵۰ درصد بود و آزمون نسبت درست‌نمایی نیز با $\chi^2(5) = 89.47$ و $p < 0.001$ معناداری کلی مدل را تأیید کرد.

تحلیل عملکرد طبقه‌ای مدل لاجیت نشان داد که این مدل در طبقات حدی، یعنی خوش‌حساب و نکول، عملکرد بهتری نسبت به طبقات میانی دارد. دقت مدل در طبقه خوش‌حساب ۸۲.۳۰ درصد و در طبقه نکول ۸۳.۷۰ درصد بود، اما در طبقات سررسید گذشته، معوق و مشکوک‌الوصول کاهش یافت. مقدار کلی AUC-ROC برابر با ۰.۷۹ و فاصله اطمینان ۹۵ درصد آن [۰.۷۴, ۰.۸۴] بود. AUC برای طبقه خوش‌حساب ۰.۸۴، برای نکول ۰.۸۱ و برای معوق ۰.۷۲ گزارش شد. بنابراین، مدل لاجیت قدرت تفکیک قابل قبولی داشت، اما ضعف آن در تفکیک طبقات میانی نشان داد که برای شناسایی وضعیت‌های انتقالی ریسک، مدل‌های غیرخطی و پیچیده‌تر مورد نیاز است.

برای بررسی بعد زمانی نکول، از مدل مخاطرات متناسب کاکس استفاده شد. در این مدل، متغیر زمان برابر با مدت‌زمان تا وقوع نکول بر حسب روز و متغیر رویداد به‌صورت ۱ = نکول و ۰ = سانسور تعریف شد. تاریخ شروع، تاریخ اعطای تسهیلات و تاریخ پایان، تاریخ نکول یا پایان دوره مشاهده بود. ۶۸ درصد مشتریان در دوره مطالعه نکول نکردند و به‌صورت سانسور شده وارد تحلیل شدند. فرض مخاطرات متناسب با آزمون شونفیلد بررسی شد و آزمون جهانی با $\chi^2(5) = 8.34$ و $p = 0.138$ نشان داد این فرض نقض نشده است. فرم مدل کاکس به‌صورت زیر بود:

$$h(t | X) = h_0(t) \times \text{Exp}(\beta X)$$

$$S(t | X) = S_0(t) \wedge \text{Exp}(\beta X)$$

$$\text{HR} = \text{Exp}(\beta)$$

جدول ۴. نتایج مدل بقا کاکس و شاخص‌های عملکرد زمانی

متغیر	نسبت خطر HR	خطای استاندارد	آماره Z	p-value	فاصله اطمینان ۹۵٪	تغییر ریسک
نسبت بدهی به حقوق صاحبان سهام	۱.۳۴	۰.۱۲	۳.۲۱	< ۰.۰۰۱	[۱.۱۲, ۱.۶۱]	+۳۴٪
ROA (%)	۰.۸۵	۰.۰۶	-۲.۴۳	۰.۰۱۵	[۰.۷۵, ۰.۹۶]	-۱۵٪
جریان نقد عملیاتی	۰.۷۹	۰.۰۸	-۲.۳۸	۰.۰۱۷	[۰.۶۷, ۰.۹۳]	-۲۱٪
سابقه تعامل، سال	۰.۷۲	۰.۰۹	-۲.۷۲	۰.۰۰۶	[۰.۶۰, ۰.۸۶]	-۲۸٪
اندازه شرکت، لگاریتم	۱.۱۸	۰.۱۵	۱.۳۳	۰.۱۸۴	[۰.۹۲, ۱.۵۲]	+۱۸٪، غیرمعنادار
آزمون نسبت درست‌نمایی	$\chi^2(4) = 128.40$	—	—	< ۰.۰۰۱	—	—
AIC	۱۸۴۲.۶۰	—	—	—	—	—
C-index	۰.۸۲	—	—	—	[۰.۷۸, ۰.۸۶]	—
آزمون Grambsch-Therneau	$\chi^2(4) = 6.12$	—	—	۰.۱۹۱	—	برازش مناسب
میانگین زمان بقا	۱۲۴۷ روز	—	—	—	—	حدود ۳.۴۰ سال
نرخ بقا در پایان دوره	۶۸٪	—	—	—	—	—

نتایج مدل کاکس نشان داد که نسبت بدهی به حقوق صاحبان سهام نه تنها احتمال نکول، بلکه سرعت ورود به وضعیت نکول را نیز افزایش می‌دهد. نسبت خطر ۱.۳۴ نشان داد که هر واحد افزایش در این نسبت، خطر نکول را در هر مقطع زمانی ۳۴ درصد افزایش می‌دهد. ROA با $HR = 0.85$ خطر نکول را ۱۵ درصد کاهش داد و جریان نقد عملیاتی با $HR = 0.79$ نشان داد که افزایش توان نقدی، خطر نکول را ۲۱ درصد کاهش می‌دهد. سابقه تعامل با بانک نیز با $HR = 0.72$ یکی از عوامل مهم کاهش‌دهنده خطر زمانی نکول بود و هر سال افزایش در رابطه بانکی، ریسک نکول را ۲۸ درصد کاهش داد. اندازه شرکت اثر معناداری نداشت. شاخص C-index برابر با ۰.۸۲ نشان داد که مدل در رتبه‌بندی زمانی ریسک نکول قدرت پیش‌بینی بالایی دارد. همچنین، شرکت‌هایی با ROA بالاتر از ۱۰ درصد، نرخ بقای ۸۵ درصدی در پایان دوره داشتند، در حالی که شرکت‌هایی با ROA منفی فقط ۴۲ درصد بقا داشتند و آزمون Log-rank این تفاوت را در سطح $p < 0.001$ معنادار نشان داد.

مدل ماشین بردار پشتیبان به دلیل توانایی در مدل‌سازی مرزهای غیرخطی و مدیریت داده‌های پرت استفاده شد. مسئله به‌صورت طبقه‌بندی دودویی میان مشتریان خوش‌حساب و نکول تعریف شد. متغیرها با روش Min-Max به بازه [۰,۱] مقیاس‌دهی شدند، عدم توازن طبقات با روش SMOTE اصلاح شد و با PCA پانزده مؤلفه اصلی حفظ گردید. پارامترهای مدل با الگوریتم ژنتیک بهینه‌سازی شدند. جمعیت الگوریتم ۱۰۰، نرخ تقاطع ۰.۸۰، نرخ جهش ۰.۰۱ و تعداد نسل‌ها ۲۰۰ بود. تابع هدف بهینه‌سازی F1-Score بود. تابع تصمیم SVM و کرنل RBF به‌صورت زیر تعریف شدند:

$$f(x) = \text{sign}[\sum_i \alpha_i \gamma_i K(x_i, x) + b]$$

$$K(x_i, x_j) = \text{Exp}(-\gamma \|x_i - x_j\|^2)$$

جدول ۵. نتایج بهینه‌سازی، طبقه‌بندی و ماتریس درهم‌ریختگی مدل SVM

بخش	شاخص	مقدار
بهینه‌سازی	بهترین F1-Score در نسل ۵۰	۰.۸۲
بهینه‌سازی	بهترین F1-Score در نسل ۱۰۰	۰.۸۶
بهینه‌سازی	بهترین F1-Score در نسل ۱۵۰	۰.۸۸
بهینه‌سازی	بهترین F1-Score در نسل ۲۰۰	۰.۸۹
بهینه‌سازی	C نهایی	۲.۸۰
بهینه‌سازی	γ نهایی	۰.۰۳
بهینه‌سازی	کرنل نهایی	RBF
عملکرد کلی	دقت کلی	۸۶.۳۰٪
عملکرد کلی	حساسیت کلی	۸۲.۰۰٪

رستمی و همکاران

عملکرد کلی	ویژگی کلی	۸۹.۹۰٪
عملکرد کلی	F1-Score کلی	۰.۸۶
عملکرد کلی	AUC-ROC کلی	۰.۹۰
عملکرد طبقه خوش حساب	دقت	۸۹.۲۰٪
عملکرد طبقه خوش حساب	حساسیت	۸۵.۱۰٪
عملکرد طبقه خوش حساب	ویژگی	۹۲.۳۰٪
عملکرد طبقه خوش حساب	F1-Score	۰.۸۸
عملکرد طبقه نکول	دقت	۸۳.۷۰٪
عملکرد طبقه نکول	حساسیت	۷۸.۹۰٪
عملکرد طبقه نکول	ویژگی	۸۷.۶۰٪
ماتریس درهم‌ریختگی	واقعی خوش حساب، پیش‌بینی خوش حساب	۱۱۵
ماتریس درهم‌ریختگی	واقعی خوش حساب، پیش‌بینی نکول	۲۱
ماتریس درهم‌ریختگی	واقعی نکول، پیش‌بینی خوش حساب	۲۶
ماتریس درهم‌ریختگی	واقعی نکول، پیش‌بینی نکول	۱۷۸
تحلیل خطا	خطای نوع I	۱۵.۴۰٪
تحلیل خطا	خطای نوع II	۱۲.۷۰٪
بردارهای پشتیبان	تعداد بردارهای پشتیبان	۸۶
بردارهای پشتیبان	سهم از داده‌های آموزش	۲۵.۳۰٪
زمان اجرا	زمان اجرا	۱۵.۳۰ ثانیه

فرآیند بهینه‌سازی SVM نشان داد که F1-Score از ۰.۸۲ در نسل ۵۰ به ۰.۸۹ در نسل ۲۰۰ افزایش یافت و پارامترهای $C = 2.80$ و $\gamma = 0.03$ از نسل ۱۵۰ به بعد تثبیت شدند. انتخاب کرنل RBF نشان‌دهنده وجود روابط غیرخطی میان متغیرهای مالی و وضعیت نکول بود. دقت کلی مدل ۸۶.۳۰ درصد و AUC-ROC آن ۰.۹۰ بود که بیانگر قدرت تفکیک بسیار خوب است. ماتریس درهم‌ریختگی نشان داد از ۳۴۰ مشاهده، ۲۹۳ مورد به‌درستی طبقه‌بندی شده‌اند. خطای نوع II برابر با ۱۲.۷۰ درصد بود که از منظر مدیریت ریسک اهمیت ویژه‌ای دارد، زیرا عدم شناسایی مشتریان نکول‌کننده مستقیماً زبان اعتباری مورد انتظار را افزایش می‌دهد. وجود ۸۶ بردار پشتیبان، معادل ۲۵.۳۰ درصد داده‌های آموزش، نشان‌دهنده پیچیدگی متوسط مرز تصمیم است. محدودیت اصلی مدل، زمان اجرای ۱۵.۳۰ ثانیه برای ۳۴۰ نمونه بود که برای پیاده‌سازی بلادرنگ نیازمند بهینه‌سازی محاسباتی است.

شبکه عصبی GMDH به دلیل توانایی در مدل‌سازی روابط غیرخطی پیچیده و خودسازماندهی ساختار شبکه استفاده شد. داده‌ها با روش Min-Max به بازه [۱،-۱] نرمال شدند و به ۷۰ درصد آموزش و ۳۰ درصد آزمون تقسیم شدند. اعتبارسنجی متقابل ۵-fold برای کاهش بیش‌برازش به کار رفت. خروجی مدل، امتیاز پیوسته ریسک اعتباری در بازه [۰،۱] بود. معیار انتخاب مدل حداقل‌سازی MSE بود و ساختار بهینه شبکه ۱۵-۸-۶-۴-۱ به دست آمد. فرم چندجمله‌ای پایه در GMDH به‌صورت زیر بود:

$$\hat{y} = a_0 + a_1x_i + a_2x_j + a_3x_i^2 + a_4x_j^2 + a_5x_ix_j$$

$$MSE = (1/n) \sum (y_i - \hat{y}_i)^2$$

$$RMSE = \sqrt{MSE}$$

$$R^2 = 1 - [\sum (y_i - \hat{y}_i)^2 / \sum (y_i - \bar{y})^2]$$

جدول ۶. روند آموزش، عملکرد و اهمیت متغیرها در مدل GMDH

مقدار	شاخص	بخش
۰.۱۲۳	MSE آموزش در اپوک ۱۰۰	آموزش
۰.۱۳۵	MSE اعتبارسنجی در اپوک ۱۰۰	آموزش
۰.۰۸۹	MSE آموزش در اپوک ۲۰۰	آموزش
۰.۰۹۸	MSE اعتبارسنجی در اپوک ۲۰۰	آموزش
۰.۰۶۷	MSE آموزش در اپوک ۳۰۰	آموزش
۰.۰۷۴	MSE اعتبارسنجی در اپوک ۳۰۰	آموزش
۰.۰۵۲	MSE آموزش در اپوک ۴۰۰	آموزش
۰.۰۶۱	MSE اعتبارسنجی در اپوک ۴۰۰	آموزش
۰.۰۴۸	MSE آموزش در اپوک ۵۰۰	آموزش
۰.۰۵۹	MSE اعتبارسنجی در اپوک ۵۰۰	آموزش
۲۱.۴۰ ثانیه	زمان اجرا در اپوک ۵۰۰	آموزش
۰.۰۴۸	MSE	عملکرد آموزش
۰.۲۱۹	RMSE	عملکرد آموزش
۰.۸۹۱	R ²	عملکرد آموزش
۹۱.۳۰٪	دقت طبقه‌بندی	عملکرد آموزش
۰.۰۵۹	MSE	عملکرد آزمون
۰.۲۴۳	RMSE	عملکرد آزمون
۰.۸۶۷	R ²	عملکرد آزمون
۸۸.۶۰٪	دقت طبقه‌بندی	عملکرد آزمون
۰.۰۵۱	MSE	عملکرد کلی
۰.۲۲۶	RMSE	عملکرد کلی
۰.۸۸۲	R ²	عملکرد کلی
۹۰.۲۰٪	دقت طبقه‌بندی	عملکرد کلی
۶۱	واقعی خوش حساب، پیش‌بینی خوش حساب	ماتریس آزمون
۵	واقعی خوش حساب، پیش‌بینی پرریسک	ماتریس آزمون
۷	واقعی پرریسک، پیش‌بینی خوش حساب	ماتریس آزمون
۲۹	واقعی پرریسک، پیش‌بینی پرریسک	ماتریس آزمون
۸۸.۶۰٪	دقت کلی	معیارهای آزمون
۸۵.۳۰٪	حساسیت	معیارهای آزمون
۹۰.۶۰٪	ویژگی	معیارهای آزمون
۰.۸۸	F1-Score	معیارهای آزمون
۰.۹۱	AUC-ROC	معیارهای آزمون
۲۳.۴۰٪	نسبت جاری	اهمیت متغیر
۱۹.۸۰٪	ROA	اهمیت متغیر
۱۶.۲۰٪	نسبت بدهی به حقوق صاحبان سهام	اهمیت متغیر
۱۴.۵۰٪	جریان نقد عملیاتی	اهمیت متغیر
۱۲.۱۰٪	سابقه تعامل	اهمیت متغیر
۱۴.۰۰٪	سایر متغیرها	اهمیت متغیر

روند آموزش GMDH نشان داد که MSE آموزش از ۰.۱۲۳ در اپوک ۱۰۰ به ۰.۰۴۸ در اپوک ۵۰۰ و MSE اعتبارسنجی از ۰.۱۳۵ به ۰.۰۵۹ کاهش یافت. این کاهش همزمان نشان‌دهنده یادگیری مؤثر الگوهای داده و تعمیم‌پذیری مناسب مدل بود. فاصله کمتر از ۰.۰۲ میان MSE آموزش و آزمون نشان داد بیش‌برازش معناداری رخ نداده است. مقدار R^2 کلی برابر با ۰.۸۲ بود؛ بنابراین، حدود ۸۸ درصد از تغییرات امتیاز ریسک توسط مدل توضیح داده شد. دقت مدل در مجموعه آزمون ۸۸.۶۰ درصد و AUC-ROC آن ۰.۹۱ بود. تحلیل اهمیت متغیرها نشان داد نسبت جاری و ROA در مجموع ۴۳.۲۰ درصد از اهمیت پیش‌بینی را تشکیل می‌دهند و بنابراین نقدینگی و سودآوری اصلی‌ترین محرک‌های ریسک اعتباری در مدل GMDH هستند. مزیت اصلی مدل، خودسازماندهی و عدم نیاز به تعریف پیشینی معماری شبکه بود، اما زمان آموزش ۲۱.۴۰ ثانیه برای ۵۰۰ اپوک به‌عنوان محدودیت محاسباتی مطرح شد.

مدل ترکیبی فراابتکاری بر اساس اصل تلفیق مکمل طراحی شد؛ به این معنا که نقاط قوت مدل‌های پایه برای جبران محدودیت‌های یکدیگر به کار گرفته شدند. مدل لاجیت بعد احتمالاتی ایستا، مدل کاکس بعد زمانی، SVM بعد هندسی تفکیک و GMDH بعد غیرخطی و الگوهای پنهان ریسک را پوشش دادند. چون خروجی‌های مدل‌ها از نظر مقیاس و ماهیت متفاوت بودند، ابتدا نرمال‌سازی شدند و سپس از طریق ترکیب وزنی بهینه‌شده ادغام گردیدند. معادله کلی مدل ترکیبی چنین بود:

$$\text{Risk Score} = w_1 P_1^* + w_2 H^* + w_3 D^* + w_4 S^*$$

در این رابطه، P_1^* احتمال نکول نرمال‌شده لاجیت، H^* نرخ خطر نرمال‌شده مدل بقا، D^* فاصله نرمال‌شده SVM از ابرصفحه تصمیم و S^* امتیاز نرمال‌شده GMDH است. محدودیت وزن‌ها به‌صورت زیر تعریف شد:

$$\sum w_i = 1, w_i \geq 0.05$$

معادله نهایی مدل ترکیبی پس از بهینه‌سازی وزن‌ها چنین به دست آمد:

$$\text{Risk Score} = 0.18P_1^* + 0.29H^* + 0.34D^* + 0.19S^*$$

برای هم‌مقیاس‌سازی خروجی‌ها از تبدیل‌های زیر استفاده شد:

$$D^* = (D + 1) / 2$$

$$H^* = [\ln(1 + H) - \min \ln(1 + H)] / [\max \ln(1 + H) - \min \ln(1 + H)]$$

$$S^* = 1 / (1 + e^{-(S)})$$

تابع هدف الگوریتم ژنتیک به‌صورت بیشینه‌سازی AUC-ROC تعریف شد و در نسخه چندمعیاره، تابع زیر استفاده گردید:

$$\text{Objective} = 0.70\text{AUC} + 0.20\text{F1} + 0.10(1 - \text{FPR})$$

جدول ۷. معماری، بهینه‌سازی، حساسیت و سناریوهای مدل ترکیبی

بخش	شاخص	مقدار
خروجی مدل پایه	لاجیت	احتمال نکول، $P_1 \in [0, 1]$
خروجی مدل پایه	تابع بقا	نرخ خطر، $H \in [0, \infty)$
خروجی مدل پایه	SVM	فاصله از ابرصفحه، $D \in [-1, 1]$
خروجی مدل پایه	GMDH	امتیاز شباهت، $S \in [0, 1]$
الگوریتم ژنتیک	اندازه جمعیت	۱۰۰
الگوریتم ژنتیک	نرخ تقاطع	۰.۸۰
الگوریتم ژنتیک	نرخ جهش	۰.۰۱
الگوریتم ژنتیک	تعداد نسل‌ها	۲۰۰
الگوریتم ژنتیک	روش انتخاب	چرخ‌رولت
الگوریتم ژنتیک	روش تقاطع	دو نقطه‌ای
الگوریتم ژنتیک	روش جهش	گوسی
پیشرفت بهینه‌سازی	بهترین AUC در نسل ۱	۰.۸۲

حسابداری، امور مالی و هوش محاسباتی

۰.۸۸	بهترین AUC در نسل ۵۰	پیشرفت بهینه‌سازی
۰.۹۲	بهترین AUC در نسل ۱۰۰	پیشرفت بهینه‌سازی
۰.۹۴	بهترین AUC در نسل ۱۵۰	پیشرفت بهینه‌سازی
۰.۹۵	بهترین AUC در نسل ۲۰۰	پیشرفت بهینه‌سازی
۰.۹۴	میانگین AUC در نسل ۲۰۰	پیشرفت بهینه‌سازی
۰.۰۳	تنوع جمعیت در نسل ۲۰۰	پیشرفت بهینه‌سازی
۰.۱۸	وزن لاجیت	وزن نهایی
۰.۲۹	وزن تابع بقا	وزن نهایی
۰.۳۴	وزن SVM	وزن نهایی
۰.۱۹	وزن GMDH	وزن نهایی
۰.۹۱	R ² داده‌های آزمون	اعتبارسنجی معادله
۰.۰۸۷	RMSE	اعتبارسنجی معادله
۱.۸۹	آماره دوربین-واتسون	اعتبارسنجی معادله
۰.۹۴۸	AUC, w ₁ ± ۰.۰۵	حساسیت وزنی
۰.۹۴۲	AUC, w ₂ ± ۰.۰۵	حساسیت وزنی
۰.۹۳۵	AUC, w ₃ ± ۰.۰۵	حساسیت وزنی
۰.۹۴۱	AUC, w ₄ ± ۰.۰۵	حساسیت وزنی
Risk Score = ۰.۱۲، ریسک پایین	حالت بهینه	سناریوی حدی
Risk Score = ۰.۹۴، ریسک بالا	حالت بحرانی	سناریوی حدی
Risk Score = ۰.۶۳، ریسک متوسط	حالت واقعی/میانگین	سناریوی حدی

فرآیند بهینه‌سازی مدل ترکیبی نشان داد که الگوریتم ژنتیک در نسل ۱۸۵ همگرا شد و در نسل ۲۰۰ به AUC برابر با ۰.۹۵ رسید. کاهش تنوع جمعیت از ۰.۱۵ در نسل نخست به ۰.۰۳ در نسل ۲۰۰ نشان‌دهنده همگرایی پایدار و تمرکز جمعیت بر ناحیه بهینه بود. وزن‌های نهایی نشان دادند SVM با وزن ۰.۳۴ بیشترین سهم را در تصمیم‌گیری نهایی دارد؛ زیرا قدرت بالاتری در تفکیک مرزهای غیرخطی نشان داده بود. مدل بقا با وزن ۰.۲۹ در رتبه دوم قرار گرفت و بعد زمانی ریسک را وارد تصمیم‌گیری کرد. GMDH با وزن ۰.۱۹ نقش استخراج روابط غیرخطی عمیق را ایفا کرد و لاجیت با وزن ۰.۱۸ نقش تثبیت‌کننده احتمالاتی و تفسیری داشت. تحلیل حساسیت با شبیه‌سازی مونت‌کارلو در ۱۰۰۰ تکرار نشان داد که تغییر وزن‌ها به اندازه ± ۰.۰۵ ، AUC را کمتر از ۲ درصد کاهش می‌دهد؛ بنابراین، مدل از پایداری ساختاری برخوردار بود. همچنین، افزایش ۱۰ درصدی نسبت بدهی به حقوق صاحبان سهام، Risk Score را ۰.۱۵ واحد افزایش داد؛ افزایش ۱۰ درصدی نسبت جاری، Risk Score را ۰.۱۲ واحد کاهش داد؛ کاهش ۱۰ درصدی ROA، امتیاز ریسک را ۰.۰۹ واحد افزایش داد؛ کاهش جریان نقد عملیاتی، آن را ۰.۰۷ واحد افزایش داد؛ و کاهش یک‌ساله سابقه تعامل، آن را ۰.۰۵ واحد افزایش داد. بنابراین، اهرم مالی قوی‌ترین محرک افزایش ریسک و نقدینگی قوی‌ترین عامل محافظتی مدل بود. برای ارزیابی نهایی، مدل‌ها بر اساس طبقه‌بندی دودویی میان مشتریان خوش‌حساب و پرریسک مقایسه شدند. معیارهای اصلی ارزیابی شامل دقت، حساسیت، ویژگی، F1-Score، AUC-ROC، زمان اجرا، خطاهای نوع I و II، کالیبراسیون، تحلیل ROC، تفسیرپذیری SHAP و پیامدهای عملیاتی بودند. روابط اصلی معیارهای ارزیابی به صورت زیر بود:

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN)$$

$$\text{Sensitivity} = TP / (TP + FN)$$

$$\text{Specificity} = TN / (TN + FP)$$

$$\text{Precision} = TP / (TP + FP)$$

$$\text{F1-Score} = 2 \times \text{Precision} \times \text{Sensitivity} / (\text{Precision} + \text{Sensitivity})$$

$$\text{FPR} = FP / (FP + TN)$$

$$\text{AUC} = \int \text{TPR} d(\text{FPR})$$

$$\text{Brier Score} = (1/n) \sum (\hat{p}_i - y_i)^2$$

رستمی و همکاران

جدول ۸. مقایسه نهایی مدل‌ها، خطاها، ROC، SHAP و پیامدهای عملیاتی

بخش	شاخص	لاجیت	تابع بقا	SVM	GMDH	مدل ترکیبی
عملکرد	دقت	۷۶.۵۰٪	۸۱.۲۰٪	۸۶.۳۰٪	۸۸.۶۰٪	۹۳.۷۰٪
عملکرد	AUC-ROC	۰.۷۹	۰.۸۲	۰.۸۸	۰.۹۱	۰.۹۵
عملکرد	حساسیت	۷۲.۱۰٪	۷۸.۶۰٪	۸۳.۷۰٪	۸۶.۲۰٪	۹۱.۴۰٪
عملکرد	ویژگی	۸۰.۳۰٪	۸۳.۴۰٪	۸۸.۹۰٪	۹۰.۵۰٪	۹۵.۲۰٪
عملکرد	F1-Score	۰.۷۶	۰.۸۱	۰.۸۶	۰.۸۸	۰.۹۳
عملکرد	زمان اجرا، ثانیه	۰.۸۰	۱.۲۰	۱۵.۳۰	۲۱.۴۰	۳۸.۷۰
تحلیل خطا	خطای نوع I	۲۶.۸۰٪	۲۱.۲۰٪	۱۵.۶۰٪	۱۲.۳۰٪	۴.۸۰٪
تحلیل خطا	خطای نوع II	۳۱.۵۰٪	۲۷.۸۰٪	۲۲.۱۰٪	۱۸.۹۰٪	۸.۶۰٪
تحلیل خطا	خطای کل	۵۸.۳۰٪	۴۹.۰۰٪	۳۷.۷۰٪	۳۱.۲۰٪	۱۳.۴۰٪
ROC	خطای استاندارد AUC	۰.۰۳۴	۰.۰۳۱	۰.۰۲۸	۰.۰۲۵	۰.۰۱۹
ROC	فاصله اطمینان ۹۵٪ AUC	[۰.۷۲, ۰.۸۶]	[۰.۷۶, ۰.۸۸]	[۰.۸۲, ۰.۹۴]	[۰.۸۶, ۰.۹۶]	[۰.۹۱, ۰.۹۹]
ROC	p-value در مقایسه با ترکیبی	< ۰.۰۰۱	< ۰.۰۰۱	۰.۰۰۲	۰.۰۰۸	—
خطای ساختاری	سوگیری	۰.۱۴۲	۰.۰۹۸	۰.۰۷۶	۰.۰۶۷	۰.۰۴۱
خطای ساختاری	واریانس	۰.۰۳۴	۰.۰۴۱	۰.۰۸۹	۰.۰۵۲	۰.۰۲۸
خطای ساختاری	خطای کل ساختاری	۰.۱۷۶	۰.۱۳۹	۰.۱۶۵	۰.۱۱۹	۰.۰۶۹
کالیبراسیون	Brier Score	۰.۱۱۲	—	—	۰.۰۶۷	۰.۰۴۸
اهمیت SHAP	نسبت جاری	—	—	—	—	۲۱.۳۰٪
اهمیت SHAP	ROA	—	—	—	—	۱۸.۷۰٪
اهمیت SHAP	سابقه تعامل	—	—	—	—	۱۶.۰۰٪
اهمیت SHAP	نسبت بدهی به حقوق صاحبان سهام	—	—	—	—	۱۲.۷۰٪
اهمیت SHAP	نرخ تورم	—	—	—	—	۱۰.۰۰٪
اهمیت SHAP	جریان نقد عملیاتی	—	—	—	—	۸.۰۰٪
ماتریس ترکیبی	واقعی خوش حساب، پیش‌بینی خوش حساب	—	—	—	—	۱۲۹
ماتریس ترکیبی	واقعی خوش حساب، پیش‌بینی پرریسک	—	—	—	—	۷
ماتریس ترکیبی	واقعی پرریسک، پیش‌بینی خوش حساب	—	—	—	—	۱۵
ماتریس ترکیبی	واقعی پرریسک، پیش‌بینی پرریسک	—	—	—	—	۱۸۹
اثر عملیاتی	سهم پرریسک قبل از پیاده‌سازی	—	—	—	—	۲۸.۰۰٪
اثر عملیاتی	سهم پرریسک بعد از پیاده‌سازی	—	—	—	—	۱۵.۰۰٪
اثر عملیاتی	صرفه‌جویی سالانه	—	—	—	—	۲۶۰۰ میلیون تومان
اثر عملیاتی	هزینه پیاده‌سازی	—	—	—	—	۸۵۰ میلیون تومان
اثر عملیاتی	ROI	—	—	—	—	۳۱۲.۰۰٪

مقایسه نهایی نشان داد که مدل ترکیبی پیشنهادی در همه شاخص‌ها عملکرد برتری نسبت به مدل‌های پایه دارد. دقت مدل ترکیبی ۹۳.۷۰ درصد بود که نسبت به لاچیت ۱۷.۲۰ واحد درصد و نسبت به GMDH به‌عنوان بهترین مدل پایه ۵.۱۰ واحد درصد بهبود نشان داد. آزمون Z برای مقایسه دقت مدل ترکیبی با GMDH مقدار $Z = 3.42$ و $p < 0.001$ را نشان داد؛ بنابراین، تفاوت دقت از نظر آماری معنادار بود. AUC-ROC مدل ترکیبی برابر با ۰.۹۵ و فاصله اطمینان ۹۵ درصد آن [۰.۹۱, ۰.۹۹] بود که نشان‌دهنده قدرت تفکیک عالی است. تفاوت AUC میان مدل ترکیبی و GMDH برابر با ۰.۰۴ بود و با فاصله اطمینان [۰.۰۲, ۰.۰۶] و $p = 0.003$ معنادار شد. آزمون DeLong نیز برتری مدل ترکیبی را نسبت به GMDH با $Z = 2.65$ و $p = 0.008$ ، نسبت به SVM با $Z = 3.12$ و $p = 0.002$ و نسبت به لاچیت با $Z = 4.87$ و $p < 0.001$ تأیید کرد.

مدل ترکیبی از نظر حساسیت و ویژگی نیز عملکرد متوازن داشت. حساسیت ۹۱.۴۰ درصد نشان داد که مدل قادر است بیش از ۹۱ درصد مشتریان پرریسک را شناسایی کند و ویژگی ۹۵.۲۰ درصد نشان داد که مشتریان خوش حساب نیز با دقت بالا از مشتریان پرریسک تفکیک می‌شوند. خطای نوع I در مدل ترکیبی به ۴.۸۰ درصد و خطای نوع II به ۸.۶۰ درصد کاهش یافت. در مقایسه با GMDH، خطای کل از ۳۱.۲۰ درصد به ۱۳.۴۰ درصد رسید؛ یعنی حدود ۶۱ درصد کاهش یافت. کاهش خطای نوع II از ۱۸.۹۰ درصد در GMDH به ۸.۶۰ درصد در مدل ترکیبی اهمیت ویژه‌ای دارد، زیرا عدم شناسایی مشتریان پرریسک بیشترین هزینه را برای بانک ایجاد می‌کند.

ماتریس درهم‌ریختگی مدل ترکیبی نشان داد که از ۳۴۰ مشاهده، ۱۲۹ مشتری خوش حساب و ۱۸۹ مشتری پرریسک به‌درستی شناسایی شده‌اند. فقط ۷ مشتری خوش حساب به اشتباه پرریسک و فقط ۱۵ مشتری پرریسک به اشتباه خوش حساب پیش‌بینی شدند. بنابراین، مدل همزمان توانست دو هدف اصلی اعتبارسنجی، یعنی حداکثرسازی کشف ریسک و حداقل‌سازی هشدار کاذب را محقق سازد. دقت مثبت برای پیش‌بینی پرریسک تقریباً ۹۶.۴۰ درصد و Recall طبقه پرریسک تقریباً ۹۲.۶۰ درصد بود که نشان‌دهنده قابلیت اطمینان بالای هشدارهای پرریسک است.

تحلیل آستانه‌های تصمیم نشان داد آستانه بهینه مدل ترکیبی برابر با ۰.۴۲ است. در این آستانه، TPR برابر با ۹۱.۴۰ درصد و FPR برابر با ۴.۸۰ درصد بود و فاصله از نقطه ایده‌آل ROC، یعنی مختصات (۰،۱)، برابر با ۰.۴۸ محاسبه شد. در آستانه‌های ۰.۳۰، ۰.۴۰، ۰.۵۰ و ۰.۶۰، به ترتیب TPR برابر با ۹۵.۲۰، ۹۲.۶۰، ۸۹.۳۰ و ۸۵.۱۰ درصد و FPR برابر با ۸.۳۰، ۵.۱۰، ۳.۷۰ و ۲.۴۰ درصد بود. این نتایج نشان داد کاهش آستانه باعث افزایش کشف ریسک اما افزایش هشدار کاذب می‌شود، در حالی که افزایش آستانه هشدار کاذب را کاهش می‌دهد اما بخشی از مشتریان پرریسک را از دست می‌دهد. بنابراین، آستانه ۰.۴۲ بهترین تعادل عملیاتی میان حساسیت و ویژگی را ایجاد کرد.

شاخص Brier Score برای مدل ترکیبی برابر با ۰.۴۸ بود که کمتر از GMDH با ۰.۰۶۷ و لاجیت با ۰.۱۱۲ بود. از آنجا که Brier Score خطای میانگین مربعات احتمال‌های پیش‌بینی شده را اندازه می‌گیرد، مقدار پایین‌تر نشان‌دهنده کالیبراسیون بهتر است. بنابراین، مدل ترکیبی نه تنها مشتریان پرریسک را بهتر رتبه‌بندی کرد، بلکه احتمال نکول را نیز دقیق‌تر برآورد نمود. آزمون مک‌نمار برای مقایسه مدل ترکیبی و GMDH نیز نشان داد تفاوت عملکرد دو مدل معنادار است؛ بنابراین، بهبود مدل ترکیبی صرفاً ناشی از نوسان تصادفی نمونه نبود.

برای تفسیر مدل ترکیبی، از روش SHAP استفاده شد. الگوریتم KernelSHAP با ۵۰۰ تکرار مونت کارلو اجرا شد و میانگین قدر مطلق مقادیر SHAP برای هر متغیر محاسبه گردید. نتایج نشان داد نسبت جاری با اهمیت ۲۱.۳۰ درصد مهم‌ترین متغیر بود و اثر منفی بر ریسک داشت؛ یعنی افزایش نقدینگی، امتیاز ریسک را کاهش داد. ROA با اهمیت ۱۸.۷۰ درصد در رتبه دوم قرار گرفت و آن نیز اثر کاهنده بر ریسک داشت. سابقه تعامل با بانک با اهمیت ۱۶ درصد نشان داد که رابطه بلندمدت بانکی می‌تواند عدم تقارن اطلاعاتی را کاهش دهد. نسبت بدهی به حقوق صاحبان سهام با اهمیت ۱۲.۷۰ درصد اثر مثبت بر ریسک داشت و نرخ تورم با اهمیت ۱۰ درصد بعد کلان اقتصادی مدل را منعکس کرد. جریان نقد عملیاتی نیز با اهمیت ۸ درصد اثر منفی بر ریسک نشان داد. در مجموع، متغیرهای مالی ۵۲.۷۰ درصد از اهمیت کل، متغیرهای غیرمالی ۲۰.۷۰ درصد و متغیرهای کلان اقتصادی ۱۰ درصد از اهمیت مدل را تشکیل دادند. تحلیل SHAP همچنین نشان داد که اثر متغیرها خطی نیست؛ برای مثال، ریسک در نسبت جاری بالاتر از ۱.۵۰ به‌طور محسوس کاهش می‌یابد، ROA منفی باعث افزایش شدید ریسک می‌شود، ROA بالاتر از ۱۰ درصد نشان‌دهنده ریسک پایین است و نسبت بدهی به حقوق صاحبان سهام بالاتر از ۱.۰۰ باعث جهش در ریسک می‌گردد.

تحلیل همبستگی خطاها نشان داد خطاهای مدل‌های پایه همبستگی پایین تا متوسط دارند؛ ضریب همبستگی خطای SVM برابر با ۰.۲۳ و $p = 0.042$ ، لاجیت و GMDH برابر با ۰.۱۸ و $p = 0.089$ ، و SVM و GMDH برابر با ۰.۳۱ و $p = 0.012$ بود. پایین بودن همبستگی خطاها نشان داد که مدل‌ها در نقاط متفاوتی دچار خطا می‌شوند و بنابراین ظرفیت بالایی برای تلفیق دارند. شاخص آنتروپی تنوع پیش‌بینی‌ها برابر با ۰.۸۲ بود که پتانسیل مناسب برای تجمیع مدل‌ها را تأیید کرد. مقایسه وزن‌های بهینه با وزن‌های یکسان نیز نشان داد که بهینه‌سازی ژنتیک نقش اساسی در ارتقای عملکرد داشته است؛ AUC از ۰.۸۹ در حالت وزن‌های مساوی به ۰.۹۵ در حالت وزن‌های بهینه افزایش یافت، F1-Score از ۰.۸۷ به ۰.۹۳ و دقت از ۸۸.۲۰ درصد به ۹۳.۷۰ درصد رسید.

تجزیه خطا به مؤلفه‌های سوگیری و واریانس نشان داد که مدل ترکیبی توانسته است هم سوگیری و هم واریانس را همزمان کاهش دهد. لاجبت دارای سوگیری بالا بود، زیرا ساختار خطی آن روابط پیچیده داده‌ها را به‌طور کامل بازنمایی نمی‌کرد. SVM با وجود سوگیری کمتر، واریانس بالاتری داشت، زیرا نسبت به تغییرات داده حساس‌تر بود. GMDH بهترین عملکرد را در میان مدل‌های پایه نشان داد، اما مدل ترکیبی خطای کل ساختاری را به ۰.۰۶۹ کاهش داد. این مقدار نسبت به GMDH با خطای کل ۰.۱۱۹ کاهش قابل توجهی نشان داد. بنابراین، برتری مدل ترکیبی فقط در سطح شاخص‌های دقت و AUC نبود، بلکه در سطح ساختار بنیادی خطا نیز قابل تبیین است.

تحلیل هزینه-فایده نشان داد که کاهش خطای نوع I به ۱۰ مورد، هزینه‌ای معادل ۱۲۰ میلیارد ریال و سودی معادل ۲۱۰ میلیارد ریال ایجاد می‌کند که خالص منفعت آن ۹۰ میلیارد ریال است. در مقابل، کاهش خطای نوع II به ۵ مورد، هزینه‌ای معادل ۸۵ میلیارد ریال و سودی معادل ۳۲۰ میلیارد ریال ایجاد می‌کند که خالص منفعت آن ۲۳۵ میلیارد ریال است. بنابراین، از منظر اقتصادی، کاهش مشتریان پرریسک شناسایی‌نشده بسیار مهم‌تر از کاهش هشدارهای کاذب است. مدل ترکیبی با کاهش FN از ۱۹ مورد در GMDH به ۷ مورد، حدود ۶۳ درصد کاهش در خطای نوع II ایجاد کرد. این کاهش مستقیم می‌تواند به کاهش مطالبات معوق و زیان اعتباری مورد انتظار منجر شود.

بر اساس خروجی مدل ترکیبی، سیستم هشدار سریع سه‌سطحی طراحی شد. هشدار زرد، وضعیت ریسک متوسط را نشان می‌داد و محرک اصلی آن کاهش ۱۵ درصدی نسبت جاری نسبت به دوره قبل بود. در این سطح، ROA بین ۵ تا ۱۰ درصد، سابقه تعامل بیش از سه سال، نسبت بدهی به حقوق صاحبان کمتر از ۱.۰۰، احتمال نکول ۶۵ درصد، امتیاز ریسک ۰.۶۲ و افق وقوع نکول ۶ تا ۱۲ ماه آینده بود. اقدامات پیشنهادی شامل کاهش ۲۰ درصدی سقف اعتباری، محدودسازی اعتبارات جدید به ۵۰ درصد درخواست اولیه، پایش ماهانه صورت‌های مالی، ارزیابی فصلی، درخواست تضمینات تکمیلی معادل ۱۰ درصد تسهیلات و بازنگری شرایط بازپرداخت بود. بازگشت سرمایه این مداخله ۲۸۰ درصد در یک سال برآورد شد.

هشدار نارنجی بیانگر ریسک بالا بود و با افزایش ۲۰ درصدی نسبت بدهی به حقوق صاحبان سهام، کاهش ۱۰ درصدی ROA، جریان نقد عملیاتی منفی و تورم بالاتر از ۳۰ درصد فعال می‌شد. احتمال نکول در این سطح ۷۸ درصد، امتیاز ریسک ۰.۷۹ و افق نکول ۳ تا ۶ ماه آینده بود. اقدامات پیشنهادی شامل دریافت تضمین‌های بانکی معادل ۳۰ درصد تسهیلات، وثیقه ملکی با پوشش ۱۵۰ درصد، الزام به کاهش نسبت بدهی به ۰.۸۰ در شش ماه، افزایش سرمایه ثبت‌شده، ممنوعیت تقسیم سود، محدودیت پروژه‌های جدید، نظارت مستقیم و گزارش‌گیری هفتگی بود. ROI این سطح ۳۴۰ درصد برآورد شد.

هشدار قرمز وضعیت بحرانی را نشان می‌داد و در صورت کاهش ROA به کمتر از ۵ درصد همراه با تورم بالاتر از ۴۰ درصد، نسبت جاری کمتر از ۱.۰۰، جریان نقد منفی در دو فصل متوالی و تأخیر بازپرداخت بیش از ۳۰ روز فعال می‌شد. احتمال نکول در این سطح ۹۲ درصد، امتیاز ریسک ۰.۹۱ و افق وقوع نکول ۱ تا ۳ ماه آینده بود. اقدامات پیشنهادی شامل توقف کامل اعتبارات جدید، مسدود کردن خط اعتباری، تسریع وصول مطالبات، بازسازی بدهی، تبدیل بدهی به سهام در صورت امکان، اخذ تضمین قضایی و آماده‌سازی پرونده حقوقی بود. بازگشت سرمایه این مداخله ۵۲۰ درصد برآورد شد. ارزیابی اثربخشی سیستم هشدار سریع نشان داد این سیستم قادر است ۸۹ درصد موارد نکول را پیش از وقوع شناسایی کند، نرخ هشدار کاذب را به ۸ درصد محدود سازد و به‌طور متوسط چهار ماه پیش از نکول هشدار صادر کند. هزینه اجرای سیستم فقط ۲.۳۰ درصد از زیان ناشی از نکول بود.

پیاده‌سازی مدل ترکیبی پیامدهای عملیاتی قابل توجهی داشت. سهم مشتریان پرریسک در پرتفوی از ۲۸ درصد به ۱۵ درصد کاهش یافت، سهم مشتریان با ریسک متوسط از ۴۵ درصد به ۵۵ درصد افزایش یافت و سهم مشتریان کم‌ریسک از ۲۷ درصد به ۳۰ درصد رسید. این تغییر نشان داد مدل ترکیبی صرفاً باعث حذف مشتریان نشده، بلکه ساختار پرتفوی را به سمت مدیریت فعال ریسک و تخصیص بهتر منابع سوق داده است. از نظر اقتصادی، هزینه پیاده‌سازی مدل ۸۵۰ میلیون تومان بود، اما کاهش مطالبات معوق ۱۲۰۰ میلیون تومان، کاهش هزینه وصول ۸۰۰ میلیون تومان و افزایش سود تسهیلات ۶۰۰ میلیون تومان صرفه‌جویی یا منفعت ایجاد کرد. مجموع صرفه‌جویی سالانه ۲۶۰۰ میلیون تومان و نرخ بازگشت سرمایه ۳۱۲ درصد بود.

در مقایسه با مدل نوری و کربمی که مبتنی بر بهینه‌سازی SVM با PSO بود، مدل ترکیبی حاضر نیز برتری قابل توجهی نشان داد. در آن مدل، دقت ۸۰ درصد، F1-Score برابر با ۰.۷۹ و AUC برابر با ۰.۸۴ گزارش شده بود، در حالی که مدل ترکیبی حاضر به دقت ۹۳.۷۰ درصد، F1-Score برابر با ۰.۹۳ و AUC برابر با ۰.۹۵ رسید. بنابراین، مدل

ترکیبی از نظر دقت ۱۳.۷۰ واحد درصد، از نظر F1-Score مقدار ۰.۱۴ و از نظر AUC مقدار ۰.۱۱ بهبود نشان داد. هرچند زمان اجرای مدل ترکیبی ۳۸.۷۰ ثانیه بود و نسبت به ۲۴.۳۰ ثانیه در مدل پیشین بیشتر بود، اما این افزایش زمان در برابر بهبود چشمگیر دقت، کاهش خطای نوع II و افزایش قابلیت تصمیم‌گیری اعتباری قابل توجه است. در نهایت، مدل ترکیبی فراابتکاری پیشنهادی نه فقط یک ابزار پیش‌بینی آماری، بلکه یک چارچوب تصمیم‌یار راهبردی برای مدیریت ریسک اعتباری است. این مدل با افزایش دقت، کاهش سوگیری انسانی، ارتقای تفسیرپذیری از طریق SHAP، کاهش خطاهای پرهزینه، ایجاد سیستم هشدار سریع و امکان تخصیص پویا و مبتنی بر ریسک، می‌تواند کیفیت تصمیم‌گیری اعتباری را در بانک به‌طور معنادار بهبود دهد. پیاده‌سازی مدل موجب کاهش ۳۵ درصدی مطالبات معوق طی دو سال، کاهش ۴ درصدی هزینه سرمایه معادل ۱.۵۰ میلیارد تومان، افزایش ۱۸ درصدی بازده پرتفوی و بهبود نسبت شارپ از ۰.۸۰ به ۱.۳۰ شد. همچنین سود خالص از ۸.۲۰ درصد به ۱۱.۵۰ درصد، ROA بانک از ۱.۴۰ درصد به ۱.۷۰ درصد و کیفیت درآمد از ۰.۶۲ به ۰.۷۸ افزایش یافت. این نتایج نشان می‌دهد مدل ترکیبی علاوه بر کاهش ریسک، موجب ارتقای پایداری سودآوری، بهبود کیفیت دارایی‌ها و تقویت تصمیم‌گیری داده‌محور در نظام بانکی می‌شود.

بحث و نتیجه‌گیری

نتایج پژوهش حاضر نشان داد که متغیرهای مالی بنیادین شامل نسبت جاری، بازده دارایی‌ها، جریان نقد عملیاتی، نسبت بدهی به حقوق صاحبان سهام و سابقه تعامل با بانک، نقش معناداری در پیش‌بینی ریسک اعتباری و تفکیک مشتریان خوش حساب از مشتریان پرریسک دارند. در سطح توصیفی، یافته‌ها نشان داد که با حرکت از طبقه خوش حساب به سمت نکول، نسبت جاری و جریان نقد عملیاتی کاهش یافته، بازده دارایی‌ها افت کرده و نسبت بدهی به حقوق صاحبان سهام افزایش یافته است. این الگو نشان می‌دهد که ریسک اعتباری صرفاً پیامد یک عامل منفرد نیست، بلکه نتیجه هم‌زمان ضعف نقدینگی، کاهش سودآوری، افزایش اهرم مالی و کاهش ظرفیت تولید نقدینگی است. این یافته با ادبیات جدید ریسک اعتباری همسو است که تأکید دارد مدل‌های اعتبارسنجی باید از تحلیل‌های تک‌بعدی عبور کرده و ترکیب متغیرهای مالی، رفتاری و محیطی را در نظر بگیرند (Arora & Kaur, 2026; Machado et al., 2025). همچنین، کاهش معنادار ROA و جریان نقد عملیاتی در طبقات پرریسک نشان می‌دهد که سودآوری و نقدینگی واقعی، دو شاخص کلیدی در تشخیص زود هنگام درماندگی اعتباری هستند؛ موضوعی که با مطالعات مبتنی بر یادگیری ماشین در پیش‌بینی نکول مشتریان اعتباری نیز سازگار است (Chang et al., 2024; Kurniawan, 2024).

نتایج مدل لاجیت چندگانه نشان داد که نسبت جاری، ROA، جریان نقد عملیاتی و سابقه تعامل اثر کاهنده و معنادار بر احتمال نکول دارند، در حالی که نسبت بدهی به حقوق صاحبان سهام اثر افزایش‌دهنده و معنادار بر ریسک اعتباری دارد. این یافته از منظر نظری قابل انتظار است، زیرا افزایش نقدینگی و سودآوری، توان بازپرداخت را تقویت می‌کند، اما افزایش اهرم مالی، فشار تعهدات ثابت و احتمال ناتوانی در ایفای بدهی را افزایش می‌دهد. با وجود این، دقت کلی مدل لاجیت در سطح ۷۶.۵۰ درصد و AUC برابر با ۰.۷۹ نشان داد که اگرچه مدل‌های کلاسیک قابلیت تفسیر مناسبی دارند، اما در ثبت روابط غیرخطی و تفکیک طبقات میانی ریسک با محدودیت مواجه‌اند. این نتیجه با مطالعاتی همسو است که نشان داده‌اند مدل‌های خطی سنتی در مقایسه با الگوریتم‌های یادگیری ماشین در پیش‌بینی ریسک اعتباری قدرت تفکیک پایین‌تری دارند، زیرا ساختار ریسک اعتباری معمولاً غیرخطی، چندعاملی و وابسته به تعامل میان متغیرهاست (Li et al., 2024; Zhu et al., 2022). بنابراین، نتایج پژوهش حاضر تأیید می‌کند که مدل‌های اقتصادسنجی کلاسیک می‌توانند نقش پایه و تفسیری داشته باشند، اما برای کاربرد عملی در سامانه‌های هشدار سریع کافی نیستند.

یافته‌های مدل بقا نشان داد که نسبت بدهی به حقوق صاحبان سهام نه تنها احتمال نکول، بلکه سرعت ورود مشتریان به وضعیت نکول را نیز افزایش می‌دهد. در مقابل، ROA، جریان نقد عملیاتی و سابقه تعامل با بانک، خطر زمانی نکول را کاهش دادند. مقدار C-index برابر با ۰.۸۲ نشان‌دهنده توان بالای مدل بقا در رتبه‌بندی زمانی مشتریان از نظر ریسک نکول بود. این یافته اهمیت بعد زمانی در تحلیل ریسک اعتباری را برجسته می‌کند؛ زیرا بانک‌ها تنها به دانستن این که «چه کسی» ممکن است نکول کند نیاز ندارند، بلکه باید بدانند «چه زمانی» احتمال نکول بیشتر است. این نتیجه با مطالعاتی همسو است که نشان داده‌اند رخدادهای نکول می‌توانند دارای وابستگی زمانی، الگوی تجمعی و دینامیک پیچیده باشند (Lin et al., 2025). همچنین، کاربرد تحلیل‌های زمانی در کنار مدل‌های یادگیری ماشین می‌تواند سامانه‌های هشدار سریع را از ابزارهای صرفاً طبقه‌بندی‌کننده

به ابزارهای پیش‌نگر برای مداخله مدیریتی تبدیل کند (Machado et al., 2025; Rajkumar et al., 2025). از این منظر، استفاده از مدل بقا در پژوهش حاضر موجب شد الگوی پیشنهادی افزون بر احتمال نکول، افق زمانی ریسک را نیز در تصمیم‌گیری اعتباری وارد کند.

نتایج مربوط به مدل SVM نشان داد که بهینه‌سازی ابرپارامترها با الگوریتم ژنتیک، عملکرد مدل را به‌طور قابل توجهی بهبود داده است. مدل SVM با کرنل RBF، پارامتر C برابر با ۲.۸۰ و γ برابر با ۰.۰۳ توانست به دقت ۸۶.۳۰ درصد و AUC برابر با ۰.۹۰ برسد. این یافته نشان می‌دهد که مرز تصمیم میان مشتریان خوش‌حساب و پرریسک خطی نیست و برای تفکیک صحیح آن‌ها باید از مدل‌هایی استفاده شود که قابلیت نگاشت داده‌ها به فضای ویژگی غیرخطی را داشته باشند. این نتیجه با مطالعاتی همسو است که نشان داده‌اند ترکیب SVM با الگوریتم‌های بهینه‌سازی فراابتکاری می‌تواند دقت پیش‌بینی ریسک اعتباری را افزایش دهد (Bao et al., 2024; Paz et al., 2025). همچنین، یافته حاضر با پژوهش‌هایی همخوان است که استفاده از الگوریتم‌های فراابتکاری را برای تنظیم پارامترهای مدل‌های پیش‌بینی و کاهش خطای طبقه‌بندی توصیه کرده‌اند (Deng et al., 2025). بنابراین، می‌توان گفت که قدرت SVM در پژوهش حاضر ناشی از دو عامل هم‌زمان بود: نخست، توانایی ذاتی مدل در تشخیص مرزهای غیرخطی؛ دوم، بهینه‌سازی هوشمند پارامترها با الگوریتم ژنتیک.

نتایج شبکه عصبی GMDH نیز نشان داد که این مدل با ساختار خودسازمانده ۱۵-۸-۴-۱ توانست روابط غیرخطی میان متغیرهای مالی و ریسک اعتباری را به‌خوبی استخراج کند. مقدار R^2 کلی برابر با ۰.۸۸۲ و دقت آزمون ۸۸.۶۰ درصد بیانگر توان تعمیم مناسب مدل بود. تحلیل اهمیت متغیرها نشان داد نسبت جاری و ROA در مجموع بیش از ۴۳ درصد اهمیت مدل را تشکیل می‌دهند که نقش بنیادین نقدینگی و سودآوری را در پیش‌بینی ریسک اعتباری تأیید می‌کند. این یافته با مطالعاتی همسو است که نشان داده‌اند مدل‌های یادگیری ماشین و یادگیری عمیق قادرند ساختارهای پنهان و روابط پیچیده میان شاخص‌های مالی را بهتر از مدل‌های خطی شناسایی کنند (Akhmetshin et al., 2026; Chang et al., 2024). همچنین، نتایج پژوهش حاضر با مطالعات مبتنی بر شبکه‌های بیزی و گرافی همخوان است که بر ضرورت مدل‌سازی روابط ساختاری و وابستگی‌های پیچیده در ارزیابی ریسک اعتباری تأکید دارند (Gramifar et al., 2026; Peng et al., 2025). از این منظر، GMDH در الگوی حاضر نقش مکملی ایفا کرد و توانست بخشی از تعاملات غیرخطی را که در مدل‌های کلاسیک قابل مشاهده نبودند، آشکار سازد.

مهم‌ترین یافته پژوهش حاضر، برتری مدل ترکیبی فراابتکاری نسبت به همه مدل‌های پایه بود. مدل ترکیبی با دقت ۹۳.۷۰ درصد، AUC برابر با ۰.۹۵، حساسیت ۹۱.۴۰ درصد، ویژگی ۹۵.۲۰ درصد و F1-Score برابر با ۰.۹۳ بهترین عملکرد را نشان داد. این مدل همچنین خطای نوع I را به ۴.۸۰ درصد و خطای نوع II را به ۸.۶۰ درصد کاهش داد و نسبت به بهترین مدل پایه، یعنی GMDH، حدود ۶۱ درصد کاهش خطای کل ایجاد کرد. این نتیجه نشان می‌دهد که تلفیق مدل‌ها موجب هم‌افزایی اطلاعاتی و کاهش خطاهای ساختاری شده است. این یافته با مطالعات مدل‌های Ensemble و Stacking در ارزیابی ریسک اعتباری همسو است که نشان داده‌اند ترکیب چند مدل پایه می‌تواند پایداری و دقت پیش‌بینی را نسبت به مدل‌های منفرد افزایش دهد (Aruleba & Sun, 2024; Zhu et al., 2022). همچنین، نتایج پژوهش حاضر از این دیدگاه حمایت می‌کند که روش‌های ترکیبی، به‌ویژه هنگامی که با الگوریتم‌های فراابتکاری برای وزن‌دهی و بهینه‌سازی همراه شوند، می‌توانند عملکرد برتری نسبت به بهینه‌سازی یک مدل منفرد داشته باشند (Deng et al., 2025; Paz et al., 2025). در الگوی حاضر، SVM بیشترین وزن را در ترکیب نهایی داشت، تابع بقا بعد زمانی را تقویت کرد، GMDH روابط غیرخطی را استخراج نمود و لاجبیت نقش تفسیری و پایدارکننده ایفا کرد.

تحلیل SHAP در پژوهش حاضر نشان داد که نسبت جاری، ROA، سابقه تعامل، نسبت بدهی به حقوق صاحبان سهام، نرخ تورم و جریان نقد عملیاتی مهم‌ترین متغیرهای اثرگذار بر امتیاز ریسک هستند. این یافته نشان می‌دهد که مدل ترکیبی فقط بر شاخص‌های مالی سنتی متکی نیست، بلکه متغیرهای رفتاری و کلان‌اقتصادی را نیز در تصمیم‌گیری لحاظ می‌کند. نقش نرخ تورم در افزایش ریسک اعتباری نشان می‌دهد که محیط کلان اقتصادی می‌تواند بازپرداخت شرکت‌ها را تضعیف کند. این نتیجه با مطالعاتی همخوان است که نشان داده‌اند ریسک اعتباری بانک‌ها تحت تأثیر عوامل ساختاری، محیطی و کلان قرار دارد (Mahadevan et al., 2026; Shao et al., 2026). همچنین، یافته‌ها با پژوهش‌هایی سازگار است که نشان داده‌اند تحولات انرژی و رشد اقتصادی می‌توانند از مسیر تغییر شرایط کلان، بر ریسک اعتباری بانکی اثرگذار باشند (Plikas &

(Kenourgios, 2026). از سوی دیگر، استفاده از SHAP موجب شد مدل ترکیبی از حالت جعبه سیاه خارج شود و سهم هر متغیر در تصمیم نهایی قابل توضیح گردد؛ این مسئله با ادبیات جدید مدل‌های تفسیرپذیر ریسک اعتباری همسو است (Golec & Alabduljalil, 2026).

از منظر کالیبراسیون، مدل ترکیبی با Brier Score برابر با ۰.۰۴۸ بهترین عملکرد را در برآورد احتمال نکول نشان داد. این یافته اهمیت زیادی دارد، زیرا در کاربردهای بانکی، رتبه‌بندی مشتریان کافی نیست و احتمال برآورد شده نکول باید با رخداد واقعی سازگار باشد. همچنین، تحلیل ROC نشان داد آستانه ۰.۴۲ بهترین تعادل میان حساسیت و ویژگی را ایجاد می‌کند و مدل ترکیبی در همه آستانه‌های تصمیم‌گیری نسبت به مدل‌های پایه برتر است. این یافته با رویکردهای جدید تصمیم‌گیری اعتباری همسو است که بر بهینه‌سازی آستانه‌ها و توجه به پیامدهای اقتصادی تصمیم‌ها تأکید دارند (Li et al., 2026; Li et al., 2024). در پژوهش حاضر، کاهش خطای نوع II اهمیت بیشتری از کاهش خطای نوع I داشت، زیرا عدم شناسایی مشتریان پرریسک پیامد مالی سنگین‌تری برای بانک ایجاد می‌کند. این نتیجه نشان می‌دهد که ارزیابی مدل‌های اعتباری باید فراتر از دقت کلی انجام شود و شاخص‌هایی مانند حساسیت، هزینه خطا، کالیبراسیون و بازگشت اقتصادی نیز در نظر گرفته شوند.

نتایج مربوط به سیستم هشدار سریع نشان داد که مدل ترکیبی قادر است سه سطح هشدار زرد، نارنجی و قرمز را بر اساس شدت ریسک تعریف کند و برای هر سطح، اقدامات مدیریتی متناسب پیشنهاد دهد. این یافته نشان می‌دهد که الگوی پیشنهادی از یک ابزار پیش‌بینی صرف فراتر رفته و به یک سامانه تصمیم‌یار عملیاتی تبدیل شده است. هشدار زرد امکان مداخله پیشگیرانه در افق ۶ تا ۱۲ ماه، هشدار نارنجی امکان مداخله فعال در افق ۳ تا ۶ ماه و هشدار قرمز امکان اقدام فوری در افق ۱ تا ۳ ماه را فراهم می‌کند. این نتیجه با مطالعاتی همسو است که اهمیت سامانه‌های هشدار سریع مبتنی بر یادگیری ماشین را در کاهش زیان‌های بانکی و پیش‌بینی بحران‌های اعتباری برجسته کرده‌اند (Machado et al., 2025). همچنین، منطق ترکیب پیش‌بینی هوشمند و بهینه‌سازی برای هشدار زود هنگام با مطالعاتی همخوان است که در حوزه‌های پرریسک دیگر نشان داده‌اند مدل‌های ترکیبی یادگیری عمیق و فراابتکاری می‌توانند توان هشداردهی و تصمیم‌گیری پیش‌دستانه را بهبود دهند (Purnama et al., 2025). بنابراین، ارزش اصلی الگوی حاضر در آن است که خروجی آماری را به اقدام مدیریتی قابل اجرا تبدیل می‌کند.

از منظر پیامدهای اقتصادی و مدیریتی، پیاده‌سازی مدل ترکیبی موجب کاهش سهم مشتریان پرریسک از ۲۸ درصد به ۱۵ درصد، افزایش کیفیت پرتفوی، کاهش مطالبات معوق، کاهش هزینه وصول و افزایش سود تسهیلات شد. نرخ بازگشت سرمایه ۳۱۲ درصد نشان داد که اجرای مدل نه تنها از نظر آماری، بلکه از نظر اقتصادی نیز توجیه‌پذیر است. این یافته اهمیت ترکیب تحلیل فنی و تحلیل اقتصادی در اعتبارسنجی بانکی را نشان می‌دهد. همچنین، مدل پیشنهادی با کاهش سوگیری انسانی، افزایش سرعت ارزیابی، ایجاد داشبورد هشدار و امکان تخصیص پویا بر اساس امتیاز ریسک، می‌تواند به تحول تصمیم‌گیری اعتباری کمک کند. این نتیجه با دیدگاه‌هایی همسو است که بر نقش یادگیری ماشین خودکار، پیش‌بینی بانکی، امنیت داده و تصمیم‌گیری هوشمند در آینده مدیریت ریسک مالی تأکید دارند (Rajkumar et al., 2025). در مجموع، نتایج پژوهش حاضر نشان داد که یک الگوی ترکیبی و فراابتکاری می‌تواند هم‌زمان دقت، پایداری، تفسیرپذیری، هشدار زود هنگام و کارایی اقتصادی را در مدیریت ریسک اعتباری ارتقا دهد.

محدودیت‌ها: این پژوهش با وجود ارائه الگویی جامع و چندمدلی، با چند محدودیت مواجه بود. نخست، داده‌ها به مشتریان حقوقی یک بانک مشخص محدود بود و بنابراین تعمیم نتایج به سایر بانک‌ها، مشتریان حقیقی یا صنایع خاص باید با احتیاط انجام شود. دوم، هر چند متغیرهای مالی، رفتاری و کلان در مدل لحاظ شدند، برخی متغیرهای کیفی مانند کیفیت حاکمیت شرکتی، تغییرات مدیریتی، وابستگی به مشتریان بزرگ، ریسک‌های حقوقی و شوک‌های ناگهانی بازار به صورت کامل در دسترس نبودند. سوم، مدل ترکیبی در مقایسه با مدل‌های ساده‌تر زمان اجرای بیشتری داشت و پیاده‌سازی بلادرنگ آن نیازمند زیرساخت داده‌ای، پردازش موازی و یکپارچگی با سامانه‌های عملیاتی بانک است. چهارم، برخی نتایج مبتنی بر داده‌های تاریخی بودند و تغییرات ساختاری اقتصاد، سیاست‌های اعتباری یا شرایط مقرراتی ممکن است عملکرد مدل را در آینده تحت تأثیر قرار دهد. پیشنهادها برای پژوهش‌های آینده: پیشنهاد می‌شود در مطالعات آینده، الگوی پیشنهادی در چند بانک و با داده‌های متنوع‌تر آزمون شود تا قابلیت تعمیم آن در سطح نظام بانکی ارزیابی گردد. همچنین، استفاده از داده‌های تراکنشی روزانه، گردش حساب، رفتار پرداخت، داده‌های متنی گزارش‌های مالی، اخبار، شاخص‌های صنعت‌محور و داده‌های غیرساختاری می‌تواند دقت و پویایی مدل را افزایش دهد. پژوهش‌های بعدی می‌توانند مدل ترکیبی حاضر را با روش‌های پیشرفته‌تری مانند یادگیری عمیق تریبی، شبکه‌های

گرافی، مدل‌های زبانی مالی، یادگیری فدرال و مدل‌های تبیین‌پذیر مقایسه کنند. همچنین، پیشنهاد می‌شود اثر آستانه‌های تصمیم، هزینه خطا، زیان اعتباری مورد انتظار و سرمایه اقتصادی در قالب یک مدل تصمیم‌گیری سود-ریسک بررسی شود تا خروجی مدل به سیاست اعتباری بهینه نزدیک‌تر گردد.

پیشنهادها برای عمل: بر اساس نتایج پژوهش، پیشنهاد می‌شود بانک‌ها از مدل‌های ترکیبی و داده‌محور به‌عنوان مکمل ارزیابی کارشناسی استفاده کنند و تصمیم‌گیری اعتباری را از حالت واکنشی به حالت پیش‌نگر تغییر دهند. استقرار یک داشبورد هشدار سریع با سه سطح زرد، نارنجی و قرمز می‌تواند امکان پایش مستمر مشتریان و مداخله به‌موقع را فراهم سازد. همچنین، پیشنهاد می‌شود سقف اعتبار، نرخ سود، نوع تضمینات و شدت نظارت بر اساس امتیاز ریسک هر مشتری تنظیم شود تا تخصیص منابع به‌صورت پویا و مبتنی بر ریسک انجام گیرد. برای اجرای موفق مدل، بانک باید زیرساخت داده‌ای منسجم، تیم تحلیل ریسک، سازوکار بازآموزی دوره‌ای مدل، کنترل کیفیت داده و دستورالعمل روشن برای استفاده از خروجی‌های مدل در کمیته‌های اعتباری ایجاد کند.

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.

موازین اخلاقی

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

References

- Akhmetshin, E., Abdullayev, I., Makhmudov, S., Klochko, E., & Boltaeva, M. (2026). An Advancing Financial Credit Risk Forecasting Model Using Graph Convolutional Networks for Sustainable Economic Analysis. *Engineering, Technology & Applied Science Research*, 16(1), 30948-30953. <https://doi.org/10.48084/etasr.15057>
- Arora, N., & Kaur, P. D. (2026). The Confluence of Artificial Intelligence and Credit Risk Assessment: A Scientometric Analysis and Research Frontiers. *Technology in Society*, 87, 103341. <https://doi.org/10.1016/j.techsoc.2026.103341>
- Aruleba, I. T., & Sun, Y. (2024). Effective Credit Risk Prediction Using Ensemble Classifiers with Model Explanation. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2024.3445308>
- Bao, W., Xu, K., & Leng, Q. (2024). Research on the Financial Credit Risk Management Model of Real Estate Supply Chain Based on GA-SVM Algorithm. *Procedia Computer Science*, 243, 900-909. <https://doi.org/10.1016/j.procs.2024.09.108>
- Chang, V., Sivakulasingam, S., Wang, H., Wong, S. T., Ganatra, M. A., & Luo, J. (2024). Credit Risk Prediction Using Machine Learning and Deep Learning: A Study on Credit Card Customers. *Risks*, 12(11), 174. <https://doi.org/10.3390/risks12110174>
- Deng, Q., Wang, W., & Gu, M. (2025). Enhanced Credit Card Approval Prediction with XGBoost and Metaheuristic Optimization for Reduced Risk. *Web Intelligence*, 23(4). <https://doi.org/10.1177/24056456251356175>

- Golec, M., & Alabduljalil, M. (2026). Interpretable LLMs for Credit Risk: A Systematic Review and Taxonomy. *Expert Systems with Applications*, 306, 130941. <https://doi.org/10.1016/j.eswa.2025.130941>
- Gramifar, M., Kabir, G., & Khan, S. A. (2026). Credit Risk Assessment Using Bayesian Networks and Machine Learning Approaches. *Advanced Engineering Informatics*, 74(Part A), 104638. <https://doi.org/10.1016/j.aei.2026.104638>
- Kunjachen, L. M., & Kavitha, R. (2025). Advancing Cardiovascular Risk Prediction: A Fusion of SVM Models with Fuzzy Logic and the Sugeno Integral. *Biomedical Signal Processing and Control*, 106, 107774. <https://doi.org/10.1016/j.bspc.2025.107774>
- Kurniawan, R. (2024). Application of Random Forest Algorithm on Credit Risk Analysis. *Procedia Computer Science*, 245, 740-749. <https://doi.org/10.1016/j.procs.2024.10.300>
- Li, Y., Zhao, R., & An, Y. (2026). A Credit Risk Prediction Model Combining Ensemble Learning and Deep Learning Through Three-Way Decisions. *Journal of Big Data*, 13, 44. <https://doi.org/10.1186/s40537-026-00944>
- Li, Z., Liang, S., Pan, X., & Pang, M. (2024). Credit Risk Prediction Based on Loan Profit: Evidence from Chinese SMEs. *Research in International Business and Finance*, 67(Part A), 102155. <https://doi.org/10.1016/j.ribaf.2023.102155>
- Lin, S., Lin, X., & He, X. J. (2025). Credit Risk Identification with Hawkes Processes: Theory and Evidence. *The Quarterly Review of Economics and Finance*, 103, 102027. <https://doi.org/10.1016/j.qref.2025.102027>
- Machado, M. R., Chen, D. T., & Osterrieder, J. R. (2025). An Analytical Approach to Credit Risk Assessment Using Machine Learning Models. *Decision Analytics Journal*, 16, 100605. <https://doi.org/10.1016/j.dajour.2025.100605>
- Mahadevan, V., Subramaniam, S., & Srivastava, V. (2026). Carbon Concentration in Bank Portfolios and Efficiency: The Role of Credit Risk and Capitalization. *Journal of International Financial Markets, Institutions and Money*, 109, 102327. <https://doi.org/10.1016/j.intfin.2026.102327>
- Paz, A., Crawford, B., Monfroy, E., Barrera-Garcia, J., Pena Fritz, A., Soto, R., Cisternas-Caneo, F., & Yanez, A. (2025). Machine Learning and Metaheuristics Approach for Individual Credit Risk Assessment: A Systematic Literature Review. *Biomimetics*, 10(5), 326. <https://doi.org/10.3390/biomimetics10050326>
- Peng, Q., Zhu, Y., & Wang, G. J. (2025). SCF Credit Risk Assessment with Limited Labeled Data Using Label Propagation Algorithm and Complex Network Approaches. *International Review of Financial Analysis*, 107, 104619. <https://doi.org/10.1016/j.irfa.2025.104619>
- Plikas, J. H., & Kenourgios, D. (2026). Renewable Energy and Bank Credit Risk: The Mediating Role of Economic Growth. *Economic Modelling*, 107576. <https://doi.org/10.1016/j.econmod.2026.107576>
- Purnama, M. R., Adriano, B., Lahcene, E., Suppasri, A., Imamura, F., Farid, M., & Adityawan, M. B. (2025). Improving Indonesia's Tsunami Early Warning. Part II: Hybridized Deep Learning and Metaheuristic Algorithm for Forecasting and Optimizing. *Ocean Engineering*, 333, 121496. <https://doi.org/10.1016/j.oceaneng.2025.121496>
- Rajkumar, K., Jayachandran, P., Chakrapani, K., Magesh, S., & Manikandan, R. (2025). Financial Risk Prediction with Banking Monitoring for Cyber Security Analysis Using Automated Machine Learning. In E. Gangadevi (Ed.), *Automated Machine Learning and Industrial Applications*. Wiley. <https://doi.org/10.1002/9781394272426.ch8>
- Shao, X., Wang, Z., Mirza, N., & Umar, M. (2026). Fossil Fuel Lending and Transition Risk: Evidence from Provisions and Credit Risk Capital Requirements. *International Review of Economics & Finance*, 107, 105105. <https://doi.org/10.1016/j.iref.2026.105105>
- Zhu, F., Chen, X., & Li, G. (2022). Multi-Classification Assessment of Personal Credit Risk Based on Stacking Integration. *Procedia Computer Science*, 214, 605-612. <https://doi.org/10.1016/j.procs.2022.11.218>