




Journal Website

Article history:
Received 23 October 2025
Revised 23 February 2026
Accepted 03 March 2026
Published online 21 March 2026

Dynamic Management and Business Analysis

Volume 4, Issue 4, pp 1-19



E-ISSN: 3041-8933

Designing an Intelligent Support System to Identify the Financial Health of Bank Customers Based on Ensemble Deep Learning

Aliasghar Gharaei¹, Maryam Rahmaty^{2*}, Seyed Ahmad Shayannia³

¹ Department of Information Technology Management, SR.C., Islamic Azad University, Tehran, Iran

² Department of Industrial Management, Cha.C., Islamic Azad University, Chalous, Iran

³ Department of Industrial Management, Fi.C., Islamic Azad University, Firoozkoh, Iran

* Corresponding author email address: rahmaty.maryam@iau.ac.ir

Article Info

Article type:

Original Research

How to cite this article:

Gharaei, A., Rahmaty, M., & Shayannia, S. A. (2025). Designing an Intelligent Support System to Identify the Financial Health of Bank Customers Based on Ensemble Deep Learning. *Dynamic Management and Business Analysis*, 4(4), 1-19.

<https://doi.org/10.61838/dmbaj.392>



© 2025 the author(s). Published by Knowledge Management Scientific Association. This is an open access article under the terms of the Creative Commons Attribution 4.0 International (CC BY 4.0) License.

ABSTRACT

Objective: This study aimed to design an intelligent decision support system for identifying the financial health and risk priority of bank customers by integrating the expert knowledge of credit assessment professionals with ensemble deep learning models.

Methodology: This study employed an exploratory sequential mixed-methods design in two qualitative and quantitative phases. In the qualitative phase, data were collected through 16 semi-structured interviews with credit assessment and credit risk management experts working in commercial and specialized banks in Tehran and were analyzed using Graneheim and Lundman's conventional content analysis method in MAXQDA 2022. In the quantitative phase, credit and transaction data from 4,872 individual customer credit files of a large Iranian commercial bank were extracted. A three-branch hybrid architecture was developed, including a bidirectional LSTM network for modeling 12-month financial behavior trends, a fully connected network for static credit indicators, and another fully connected network for demographic variables. The dataset was divided into training, validation, and test sets, and model performance was assessed using ROC-AUC, precision, recall, F1-Score, confusion matrix, and SHAP-based explainability analysis.

Findings: The proposed hybrid model achieved a mean ROC-AUC of 0.93 and a weighted F1-Score of 0.86 on the test set. The F1-Score values for low-risk, high-risk, and critical customers were 0.93, 0.83, and 0.76, respectively. SHAP analysis indicated that debt-to-income ratio, installment coverage trend, and credit score collectively accounted for approximately 60% of the model's predictive power. Moreover, the LSTM branch alone improved predictive performance by 0.23 compared with the static baseline model.

Conclusion: Integrating tacit banking expertise with hybrid deep learning architectures can support the development of accurate, explainable, and reliable decision support systems for diagnosing customer financial health and improving credit risk management.

Keywords: Decision Support System; Ensemble Deep Learning; Financial Health; Credit Risk; Bank Credit Assessment; SHAP Analysis



EXTENDED ABSTRACT

Introduction

Credit risk remains one of the most consequential challenges in contemporary banking because the financial health of customers directly affects asset quality, profitability, capital adequacy, liquidity management, and the broader stability of the financial system. Banks operate as intermediaries between savings and investment, and the deterioration of customer repayment capacity can weaken not only individual banking institutions but also the real economy through reduced lending capacity and increased non-performing loans (Berger et al., 2020). In this context, identifying the financial health of bank customers is not a purely technical task; it is a strategic requirement for proactive risk governance, sustainable credit allocation, and early intervention before customers move toward default or insolvency. The growing complexity of banking data has increased the demand for intelligent systems capable of integrating static credit indicators, temporal financial behavior, and customer-level patterns into actionable risk classifications (Dastile et al., 2020; Petropoulos et al., 2020).

Traditional credit scoring models have contributed substantially to credit decision-making, but their limitations have become increasingly visible in dynamic and data-rich banking environments. Many conventional models rely on linear assumptions, static variables, and predefined relationships, while customer financial behavior often follows nonlinear, time-dependent, and context-sensitive patterns. Deep learning has therefore emerged as a promising approach in financial modeling because it can extract hidden representations from complex, heterogeneous, and high-dimensional data (Heaton et al., 2017, 2021). In credit risk assessment, deep learning models have shown potential for improving predictive accuracy, especially when longitudinal repayment behavior, transaction trends, and customer-level financial trajectories are incorporated into the model architecture (Gunnarsson et al., 2021; Sadhwani et al., 2021). Ensemble and hybrid deep learning approaches can further improve robustness by allowing different components of the model to process different types of financial information, including time-series behavior, static credit indicators, and demographic characteristics (Gicic & Subasi, 2023).

Despite these advantages, the operational adoption of deep learning models in banking remains constrained by two major concerns: explainability and expert trust. Credit decisions have financial, legal, ethical, and reputational consequences, and banking professionals are unlikely to rely on black-box systems whose internal decision logic cannot be understood, justified, or audited. Explainable artificial intelligence is therefore essential for responsible implementation of intelligent decision support systems in credit assessment (Arrieta et al., 2020). In credit scoring, explainability methods can help clarify which variables contribute most strongly to a model's prediction and whether the model's logic aligns with expert judgment (Dastile & Celik, 2021). This is particularly important because banking experts often rely on tacit knowledge accumulated through years of experience, including heuristic rules, warning signs, customer behavior patterns, and informal prioritization strategies that are rarely documented in formal databases (Alahmari et al., 2023). Qualitative inquiry can help elicit this implicit professional knowledge and convert it into a conceptual foundation for model design (Graneheim & Lundman, 2004).

The need for customer-centered and behavior-sensitive banking models has also grown alongside digital transformation. Digital banking, mobile banking applications, customer engagement platforms, and data-driven marketing have expanded the range of behavioral information available to banks (Maziriri et

al., 2026; Shadzad et al., 2025). Customer experience, emotional branding, and behavioral patterns are increasingly recognized as relevant to banking relationships, loyalty, and financial decision-making (Shafiei et al., 2025; Taghipourian, 2026). Similarly, customer segmentation based on advanced clustering and machine learning methods has shown that banks can design more precise strategies when customers are grouped according to meaningful behavioral and financial patterns (Yan et al., 2025). However, in credit risk management, segmentation must go beyond marketing categories and support practical risk prioritization. Accordingly, the present study aimed to design an intelligent decision support system for identifying the financial health and risk priority of bank customers by integrating the expert knowledge of credit assessment professionals with ensemble deep learning models.

Methods and Materials

This study employed an exploratory sequential mixed-methods design conducted in two main phases. The qualitative phase was implemented first to extract the tacit knowledge, decision logic, and professional priorities of banking experts. The participants in this phase were credit assessment and credit risk management specialists working in credit, risk, and marketing departments of commercial and specialized banks in Tehran. Participants were selected through purposive sampling with attention to diversity in professional experience, area of expertise, gender, and type of bank. The sample size was determined according to theoretical saturation, which was achieved after 16 semi-structured interviews.

The qualitative data were collected using an interview guide whose content validity was confirmed by banking experts. The interviews were conducted in a calm setting, recorded with participant consent, transcribed verbatim, and analyzed using conventional content analysis. The coding process included open coding, formation of subcategories, abstraction of main components, and development of a conceptual framework for the decision support system. MAXQDA 2022 software was used to manage and analyze the qualitative data. Credibility and dependability were supported through participant review and independent researcher audit.

In the quantitative phase, credit and transaction data were extracted from the records of individual customers of a large Iranian commercial bank. The final dataset included 4,872 eligible credit files selected through purposive census. Inclusion criteria included being at least 21 years old, having at least one active credit facility with a minimum 12-month repayment history, and having complete account information for at least 85% of required fields. Predictor variables included demographic characteristics, 12-month time-series indicators of financial behavior, and static credit indicators. The outcome variable was defined as three-class customer prioritization: low-risk, high-risk, and critical.

The data were randomly divided into training, validation, and test sets in proportions of 70%, 15%, and 15%, respectively. A three-branch hybrid architecture was developed. The first branch used a bidirectional LSTM network to model 12-month financial behavior trends, including monthly average account balance, transaction frequency, installment coverage ratio, and repayment delay days. The second branch used fully connected layers to process static credit indicators, including debt-to-income ratio, credit score, loan-to-collateral value ratio, previous default history, and number of credit inquiries. The third branch processed demographic variables. The outputs of the three branches were merged in a fusion layer to generate the final customer risk classification. Model training was performed using AdamW optimization and early stopping. Model performance was evaluated using precision, recall, F1-Score, ROC-AUC, confusion matrix, and SHAP analysis for explainability.

Findings

The qualitative phase resulted in the extraction of 487 initial codes, 18 subcategories, and five main components. These components were: golden indicators of credit assessment, warning signs of financial behavior, mental algorithm for risk prioritization, barriers to credit decision-making, and requirements for trust in artificial intelligence in banking. The qualitative findings showed that experts considered the combination of debt-to-income ratio, installment coverage trend, and credit score to be the core triad of credit decision-making. Participants also emphasized that a practical decision support system should not merely classify customers into default and non-default groups, but should prioritize them into three operational levels: low-risk, high-risk, and critical. Another important qualitative result was the strong expert demand for traceability, interpretability, and the ability to explain the reasons behind any model-generated decision.

In the quantitative phase, the final dataset consisted of 4,872 credit files. The training set included 3,410 cases, the validation set included 731 cases, and the test set included 731 cases. The hybrid three-branch deep learning model was trained for 150 epochs, and the early stopping mechanism was activated at epoch 98 to prevent overfitting. The model demonstrated strong classification performance on the test set. The weighted average ROC-AUC was 0.93, and the weighted F1-Score was 0.86. For the low-risk class, precision was 0.94, recall was 0.92, and F1-Score was 0.93. For the high-risk class, precision was 0.85, recall was 0.81, and F1-Score was 0.83. For the critical class, precision was 0.78, recall was 0.75, and F1-Score was 0.76.

The explainability analysis showed that the most influential predictors for classifying customers into the critical category were the latest debt-to-income ratio, the six-month trend of installment coverage ratio, the minimum credit score over the previous 12 months, the number of repayment delay days in the last three months, and the minimum average account balance over the last three months. SHAP results indicated that debt-to-income ratio, installment coverage trend, and credit score collectively accounted for approximately 60% of the model's predictive power. Furthermore, the LSTM branch alone improved predictive performance by 0.23 compared with the static baseline model. This result confirmed that temporal financial behavior contained substantial predictive information beyond static credit indicators.

Discussion and Conclusion

The findings indicate that the proposed intelligent decision support system successfully integrated expert-based conceptual logic with a hybrid deep learning architecture. The strong performance of the model, reflected in the average ROC-AUC of 0.93 and weighted F1-Score of 0.86, shows that the three-branch architecture was effective in distinguishing low-risk, high-risk, and critical customers. This three-level prioritization is practically important because it provides banks with a more operationally useful classification than binary default prediction. Low-risk customers can be processed with greater confidence, high-risk customers can be monitored and supported, and critical customers can be prioritized for urgent intervention.

The improvement created by the LSTM branch demonstrates that customer financial health is fundamentally dynamic. Static credit indicators remain important, but they are insufficient when used alone. The direction and speed of changes in installment coverage, account balance, repayment delay, and transaction behavior provide early warning signals that may not be visible in cross-sectional credit files.

The results therefore support the use of temporal modeling in credit risk management and show that behavioral trends should be treated as central inputs in intelligent banking systems.

The convergence between the qualitative and quantitative findings is one of the most important contributions of the study. Banking experts independently emphasized the same core indicators that the SHAP analysis later identified as the most influential predictors. This alignment suggests that the model did not merely achieve statistical accuracy; it learned patterns that correspond to the professional reasoning of credit experts. Such convergence strengthens the operational credibility of the proposed system and increases its potential acceptability in real banking environments.

Overall, the study concludes that combining tacit banking expertise with hybrid deep learning models can support the development of accurate, explainable, and trustworthy decision support systems for diagnosing customer financial health and prioritizing credit risk. The proposed system should be viewed not as a replacement for human experts, but as an intelligent assistant that strengthens expert judgment, reduces manual error, increases consistency, and supports proactive credit risk management.



وبسایت مجله

تاریخچه مقاله

دریافت شده در تاریخ ۱ آبان ۱۴۰۴

اصلاح شده در تاریخ ۴ اسفند ۱۴۰۴

پذیرفته شده در تاریخ ۱۲ اسفند ۱۴۰۴


منتشر شده در تاریخ ۳۰ اسفند ۱۴۰۴

مدیریت پویا و تحلیل کسب و کار

دوره ۴، شماره ۴، صفحه ۱۹-۱

فصلنامه

مدیریت پویا و
تحلیل کسب و کار



شاپای الکترونیکی: ۸۹۳۳-۳۰۴۱

طراحی یک سیستم پشتیبان هوشمند جهت شناسایی سلامت مالی مشتریان بانکی مبتنی بر یادگیری عمیق گروهی

علی اصغر قرایی^۱، مریم رحمتی^{۲*}، سید احمد شایان نیا^۳

۱. گروه مدیریت فناوری اطلاعات، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲. گروه مدیریت صنعتی، واحد چالوس، دانشگاه آزاد اسلامی، چالوس، ایران

۳. گروه مدیریت صنعتی، واحد فیروزکوه، دانشگاه آزاد اسلامی، فیروزکوه، ایران

* ایمیل نویسنده مسئول: rahmaty.maryam@iau.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله

پژوهشی اصیل

نحوه استناد به این مقاله:

قرایی، علی اصغر، رحمتی، مریم، و شایان نیا، سید احمد. (۱۴۰۴). طراحی یک سیستم پشتیبان هوشمند جهت شناسایی سلامت مالی مشتریان بانکی مبتنی بر یادگیری عمیق گروهی. مدیریت پویا و تحلیل کسب و کار، ۴(۴)، ۱-۱۹.



© ۱۴۰۴ تمامی حقوق انتشار این مقاله متعلق به نویسنده(گان) است. انتشار این مقاله به صورت دسترسی آزاد مطابق با گواهی (CC BY 4.0) صورت گرفته است.

هدف: هدف این مطالعه طراحی یک سیستم پشتیبان تصمیمگیری هوشمند برای شناسایی سلامت مالی و اولویتبندی مشتریان بانکی از طریق تلفیق دانش تخصصی کارشناسان اعتبارسنجی با مدل‌های یادگیری عمیق گروهی بود. **روش‌شناسی:** این پژوهش با رویکرد آمیخته اکتشافی - متوالی در دو فاز کیفی و کمی انجام شد. در فاز کیفی، داده‌ها از طریق ۱۶ مصاحبه نیمه‌ساختاریافته با متخصصان اعتبارسنجی و مدیریت ریسک اعتباری بانکهای تجاری و تخصصی شهر تهران گردآوری و با روش تحلیل محتوای قراردادی گرانهم و لوندمن در نرم‌افزار MAXQDA ۲۰۲۲ تحلیل شدند. در فاز کمی، داده‌های اعتباری و تراکنشی ۴۸۷۲ پرونده مشتریان حقیقی یک بانک تجاری بزرگ ایرانی استخراج شد. معماری مدل شامل سه شاخه بود: شبکه LSTM دوطرفه برای تحلیل روندهای ۱۲ ماهه رفتار مالی، شبکه کاملاً متصل برای شاخصهای اعتباری ایستا و شبکه کاملاً متصل برای متغیرهای جمعیتشناختی. داده‌ها به مجموعه‌های آموزش، اعتبارسنجی و آزمون تقسیم شدند و عملکرد مدل با معیارهای ROC-AUC، دقت، حساسیت، F1-Score و تحلیل SHAP ارزیابی شد. **یافته‌ها:** مدل ترکیبی پیشنهادی در مجموعه آزمون به ROC-AUC میانگین ۰.۹۳ و F1-Score وزنی ۰.۸۶ دست یافت. مقدار F1-Score برای مشتریان کم‌ریسک، پرریسک و بحرانی به ترتیب ۰.۹۳، ۰.۸۳ و ۰.۷۶ بود. تحلیل SHAP نشان داد نسبت بدهی به درآمد، روند نسبت پوشش اقساط و امتیاز اعتباری در مجموع حدود ۶۰ درصد از قدرت پیشبینی مدل را تشکیل دادند. همچنین، شاخه LSTM نسبت به مدل ایستای پایه ۰.۲۳ بهبود عملکرد ایجاد کرد. **نتیجه‌گیری:** تلفیق دانش ضمنی کارشناسان بانکی با معماریهای ترکیبی یادگیری عمیق میتواند به توسعه سیستمهای پشتیبان تصمیمگیری دقیق، تبیینپذیر و قابل اعتماد برای تشخیص سلامت مالی مشتریان و مدیریت ریسک اعتباری منجر شود.

کلیدواژه‌گان: سیستم پشتیبان تصمیمگیری؛ یادگیری عمیق گروهی؛ سلامت مالی؛ ریسک اعتباری؛ اعتبارسنجی بانکی؛ تحلیل

SHAP

مقدمه

نظام بانکی یکی از ارکان اصلی پایداری اقتصادی، تخصیص بهینه منابع و هدایت جریان سرمایه در اقتصادهای مدرن است. بانکها از طریق تجهیز سپردهها، اعطای تسهیلات، مدیریت نقدینگی و پشتیبانی از فعالیتهای تولیدی و تجاری، پیوندی مستقیم با عملکرد بخش واقعی اقتصاد دارند. از این منظر، سلامت مالی بانکها صرفاً یک مسئله سازمانی یا درونصنعتی نیست، بلکه با ثبات مالی، رشد اقتصادی، اشتغال، سرمایهگذاری و تابآوری کل نظام اقتصادی در ارتباط است. هرگونه اختلال در کیفیت داراییهای بانکی، افزایش مطالبات غیرجاری یا ضعف در ارزیابی توان بازپرداخت مشتریان میتواند زنجیرهای از پیامدهای منفی را در سطح خرد و کلان ایجاد کند. بنابراین، مدیریت دقیق ریسک اعتباری و شناسایی بهموقع مشتریان دارای وضعیت مالی نامطلوب، از ضروریترین الزامات حکمرانی بانکی و پایداری اقتصادی محسوب میشود (Berger et al., 2020).

در میان انواع ریسکهای بانکی، ریسک اعتباری جایگاهی ویژه دارد؛ زیرا مستقیماً با توان و تمایل مشتریان برای ایفای تعهدات مالی مرتبط است. نکول اعتباری نهنتها سبب کاهش سودآوری و افزایش هزینههای وصول مطالبات میشود، بلکه میتواند سرمایه نظارتی بانک را تحت فشار قرار داده و ظرفیت اعطای تسهیلات جدید را محدود کند. از سوی دیگر، تمرکز مشتریان پرریسک در پرتفوی اعتباری، احتمال سرایت زیان، کاهش کیفیت دارایی و حتی ناتوانی مالی بانک را افزایش میدهد. به همین دلیل، پژوهشهای نوین مالی و بانکی بر اهمیت پیشبینی زودهنگام وضعیت نکول، تفکیک مشتریان سالم از مشتریان نیازمند پایش و شناسایی مشتریان بحرانی تأکید کردهاند. استفاده از روشهای یادگیری ماشین در پیشبینی ناتوانی بانکی نیز نشان داده است که الگوهای دادهمحور میتوانند نسبت به رویکردهای سنتی، ظرفیت بیشتری برای تشخیص نشانههای پنهان بحران مالی داشته باشند (Petropoulos et al., 2020).

سلامت مالی مشتریان بانکی مفهومی چندبعدی است که تنها به درآمد یا مانده حساب محدود نمیشود، بلکه مجموعهای از شاخصهای ایستا و پویا مانند نسبت بدهی به درآمد، سابقه بازپرداخت، الگوی تراکنشها، تغییرات جریان نقدی، نسبت پوشش اقساط، تعداد روزهای تأخیر و کیفیت وثایق را دربر میگیرد. یک مشتری ممکن است در یک مقطع زمانی از نظر شاخصهای ظاهری وضعیت مطلوبی داشته باشد، اما روندهای رفتاری او در طول زمان نشانههایی از کاهش توان بازپرداخت را آشکار سازد. بنابراین، تشخیص سلامت مالی نیازمند نگاهی فراتر از امتیازدهی مقطعی است و باید بر مبنای تحلیل روندها، تعامل متغیرها و شناخت الگوهای رفتاری مشتری انجام شود. همین پیچیدگی سبب شده است که روشهای ساده خطی و قواعد ثابت اعتبارسنجی در بسیاری از موارد برای تشخیص دقیق مشتریان در معرض خطر کافی نباشند (Dastile et al., 2020).

تحول دیجیتال در بانکداری نیز ماهیت دادههای در دسترس بانکها را بهطور چشمگیری تغییر داده است. مشتریان امروز بخش قابل توجهی از تعاملات مالی خود را از طریق بانکداری موبایلی، سامانههای دیجیتال، تراکنشهای برخط و کانالهای غیرحضوری انجام میدهند. این محیط دیجیتال، حجم گستردهای از دادههای رفتاری، تراکنشی و تعاملی تولید میکند که در صورت تحلیل صحیح، میتواند نشانههای ارزشمندی درباره وضعیت مالی، الگوی مصرف، سطح درگیری مشتری با خدمات بانکی و احتمال بروز ریسک اعتباری ارائه دهد. پژوهشهای مرتبط با استفاده مستمر از اپلیکیشنهای بانکداری موبایلی نشان میدهد که رفتار دیجیتال مشتریان، بخشی از منطق جدید تعامل مالی آنان با بانکهاست و میتواند در کنار دادههای اعتباری سنتی، به فهم دقیقتر وضعیت مشتری کمک کند (Maziriri et al., 2026).

در کنار دادههای تراکنشی، ابعاد بازاریابی و تجربه مشتری نیز برای شناخت رفتار مالی مشتریان اهمیت یافته است. بانکها دیگر صرفاً با پروندههای اعتباری ایستا مواجه نیستند، بلکه با مشتریانی روبهرو هستند که تجربه، اعتماد، درگیری عاطفی و تعامل آنان با برند بانکی



میتواند بر رفتار مالی و وفاداری آنان اثر بگذارد. مطالعات اخیر درباره برندسازی عاطفی و ارزش ویژه برند در بخش بانکداری نشان دادهاند که تجربه مشتری میتواند نقش مهمی در شکلگیری نگرش و رفتار مشتریان نسبت به خدمات مالی داشته باشد (Taghipourian, 2026). از سوی دیگر، طراحی مدل‌های بازاریابی محتوای دیجیتال با رویکرد درگیری مشتری در بانکهای تجاری نیز نشان میدهد که فهم رفتار مشتریان در فضای بانکی، مستلزم توجه همزمان به دادههای مالی، دادههای رفتاری و سازوکارهای ارتباطی است (Shadzad et al., 2025).

یکی از پیامدهای مهم گسترش دادههای مشتریان، افزایش نیاز به بخشبندی دقیق و هوشمند مشتریان بانکی است. بخشبندی مشتریان بر اساس شاخصهای رفتاری، مالی و تعاملی میتواند به بانکها کمک کند تا استراتژیهای متفاوتی برای مشتریان کم‌ریسک، پرریسک و بحرانی طراحی کنند. الگوریتمهای خوشه‌بندی و روشهای بهبودیافته‌ای مانند DBSCAN در سالهای اخیر برای شناسایی الگوهای پنهان در مشتریان بانکی و تدوین راهبردهای بازاریابی و مدیریت مشتری به کار گرفته شدهاند (Yan et al., 2025). با این حال، در حوزه اعتبارسنجی، بخشبندی صرفاً یک ابزار بازاریابی نیست، بلکه میتواند به یک ضرورت مدیریت ریسک تبدیل شود؛ زیرا بانکها نیاز دارند مشتریان را بر اساس سطح سلامت مالی و اولویت مداخله، به‌صورت دقیق و قابل اتکا دستهبندی کنند.

در همین راستا، مدل‌های رفتاری مشتریان نظام بانکی نیز نشان دادهاند که تصمیمگیری مشتریان در بستر بانکی تحت تأثیر مجموعه‌ای از عوامل شناختی، تجربی، خدماتی و زمینه‌ای قرار دارد. طراحی و اعتبارسنجی مدل‌های رفتاری برای مشتریان بانکها میتواند تصویر جامع‌تری از عوامل مؤثر بر کنش مالی آنان ارائه دهد و به بانکها کمک کند تا تصمیمات اعتباری و ارتباطی خود را با شناخت دقیق‌تری اتخاذ کنند (Shafiei et al., 2025). با این حال، چالش اصلی آن است که این نوع شناخت رفتاری چگونه میتواند به شکل عملی در سیستمهای پشتیبان تصمیمگیری اعتباری ادغام شود؛ زیرا بسیاری از سامانههای اعتبارسنجی همچنان بر دادههای ساختیافته محدود و شاخصهای از پیش تعریف‌شده متکی هستند.

ادبیات اعتبارسنجی نشان میدهد که طی دهه‌های گذشته، روشهای آماری و یادگیری ماشین نقش مهمی در توسعه مدل‌های پیشبینی ریسک اعتباری داشته‌اند. مدل‌هایی مانند رگرسیون لجستیک، درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان و روشهای آن‌سبل، امکان تحلیل دادههای اعتباری را گسترش داده‌اند و در بسیاری از موارد نسبت به قضاوت کاملاً دستی، دقت بالاتری ارائه کرده‌اند. با وجود این، مرور نظاممند پژوهشها در حوزه امتیازدهی اعتباری نشان میدهد که عملکرد این مدلها به کیفیت داده، انتخاب ویژگیها، تعادل کلاسها، روش اعتبارسنجی و قابلیت تعمیم به محیطهای عملیاتی وابسته است (Dastile et al., 2020). افزون بر این، بسیاری از مدل‌های کلاسیک در تحلیل وابستگیهای زمانی و روابط غیرخطی پیچیده میان متغیرهای مالی محدودیت دارند.

ظهور یادگیری عمیق، افق جدیدی را برای تحلیل دادههای مالی و بانکی ایجاد کرده است. در حوزه مالی، شبکههای عمیق به دلیل توانایی در استخراج بازنماییهای پیچیده، کشف روابط غیرخطی و پردازش دادههای حجیم، به‌تدریج به ابزاری مهم برای تحلیل پرتفوی، پیشبینی ریسک و تصمیمگیری مالی تبدیل شده‌اند (Heaton et al., 2017). مرورهای جدیدتر نیز نشان داده‌اند که یادگیری عمیق در مالی، تنها یک ابزار پیشبینی نیست، بلکه میتواند برای استخراج الگوهای پنهان، ترکیب منابع داده ناهمگون و پشتیبانی از تصمیمگیریهای پیچیده به کار رود (Heaton et al., 2021). این ویژگیها به‌ویژه در بانکداری اهمیت دارد؛ زیرا رفتار مالی مشتریان معمولاً ترکیبی از روندهای زمانی، شاخصهای اعتباری ایستا و ویژگیهای جمعیتشناختی است.

در حوزه ریسک اعتباری، مطالعات مبتنی بر یادگیری عمیق نشان داده‌اند که شبکههای عصبی عمیق، شبکههای حافظه‌دار و معماریهای ترکیبی میتوانند عملکرد قابل توجهی در پیشبینی نکول و ارزیابی ریسک مشتریان داشته باشند. پژوهش مربوط به ریسک وام مسکن نشان داده است که مدل‌های عمیق میتوانند از دادههای گسترده برای پیشبینی دقیق‌تر ریسک استفاده کنند و الگوهای را استخراج

کنند که در روشهای سنتی کمتر آشکار میشوند (Sadhvani et al., 2021). همچنین، بررسی انتقادی یادگیری عمیق برای امتیازدهی اعتباری نشان میدهد که این مدلها در صورت طراحی مناسب، میتوانند بهبود معناداری در عملکرد پیشبینی ایجاد کنند، اما استفاده از آنها باید با دقت، اعتبارسنجی و ملاحظات عملیاتی همراه باشد (Gunnarsson et al., 2021).

با وجود مزایای مدل‌های عمیق، کاربرد آنها در اعتبارسنجی بانکی با دو چالش مهم مواجه است: نخست، مسئله تبیین‌پذیری و دوم، مسئله پذیرش عملیاتی توسط کارشناسان و مدیران. تصمیمات اعتباری به دلیل پیامدهای مالی، حقوقی و اخلاقی، نمیتوانند صرفاً بر خروجی یک مدل جعبه‌سیاه متکی باشند. بانکها باید بتوانند توضیح دهند که چرا یک مشتری در گروه کم‌ریسک، پریسک یا بحرانی قرار گرفته است و کدام متغیرها بیشترین نقش را در این تصمیم داشته‌اند. ادبیات هوش مصنوعی تبیین‌پذیر نشان میدهد که شفافیت، قابلیت فهم، اعتماد‌پذیری و مسئولیت‌پذیری از شروط اساسی کاربرد مسئولانه هوش مصنوعی در حوزه‌های حساس هستند (Arrieta et al., 2020). در اعتبارسنجی نیز روشهایی مانند SHAP میتوانند به آشکارسازی سهم هر متغیر در تصمیم مدل کمک کنند و فاصله میان دقت الگوریتمی و فهم انسانی را کاهش دهند (Dastile & Celik, 2021).

از سوی دیگر، استفاده از معماریهای گروهی و ترکیبی میتواند راهکاری مؤثر برای افزایش پایداری و دقت مدل‌های اعتبارسنجی باشد. در چنین رویکردی، به جای اتکا بر یک مدل منفرد، چندین مؤلفه یا شاخه تحلیلی برای پردازش جنبه‌های مختلف داده طراحی میشود. برای مثال، یک شاخه میتواند روندهای زمانی رفتار مالی را تحلیل کند، شاخه دیگر شاخصهای اعتباری ایستا را پردازش کند و شاخه سوم ویژگیهای جمعیتشناختی را در نظر گیرد. شواهد حاصل از کاربرد روشهای یادگیری عمیق گروهی در امتیازدهی اعتباری نشان داده است که ترکیب مدلها میتواند توان تشخیص الگوهای پیچیده را افزایش دهد و نسبت به مدل‌های منفرد عملکرد مقاومتری ارائه کند (Gicic & Subasi, 2023). بنابراین، معماری گروهی میتواند برای تشخیص سلامت مالی مشتریان بانکی مناسب باشد، زیرا این مسئله ذاتاً چندمنبعی، چندسطحی و پویاست.

با این حال، یک خلأ مهم در بسیاری از مطالعات داده‌محور آن است که طراحی مدلها غالباً بدون بهره‌گیری کافی از دانش ضمنی کارشناسان بانکی انجام میشود. کارشناسان اعتبارسنجی در طول سالها تجربه عملی، مجموعه‌های از نشانه‌های هشداردهنده، قواعد ذهنی، اولویتهای تصمیمگیری و الگوهای تشخیصی را شکل میدهند که در بسیاری از موارد در داده‌های عددی خام به‌صورت مستقیم قابل مشاهده نیست. دانش ضمنی در بانکداری، به‌ویژه در حوزه‌هایی مانند اعتبارسنجی، مدیریت ریسک و تعامل با مشتری، نقشی تعیینکننده در کیفیت تصمیمات دارد. مرور نظاممند مدیریت دانش ضمنی در بخش بانکی نشان میدهد که ثبت، انتقال و بهره‌برداری از این نوع دانش میتواند به ارتقای تصمیمگیری، کاهش خطای انسانی و تقویت عملکرد سازمانی منجر شود (Alahmari et al., 2023). بنابراین، طراحی سیستمهای هوشمند بانکی باید به جای حذف قضاوت کارشناسی، آن را در معماری تصمیمگیری خود ادغام کند.

برای استخراج این دانش ضمنی، روشهای کیفی میتوانند نقش بنیادینی ایفا کنند. مصاحبه‌های عمیق با متخصصان، تحلیل محتوای قراردادی و کدگذاری نظاممند داده‌های متنی، امکان شناسایی مؤلفه‌هایی را فراهم میکند که در تجربه حرفهای کارشناسان ریشه دارند. رویکرد تحلیل محتوای کیفی، به‌ویژه زمانی که هدف پژوهش فهم ساختارهای پنهان معنا، تجربه و تصمیمگیری است، میتواند چارچوبی معتبر برای تبدیل داده‌های روایی به طبقات مفهومی فراهم آورد (Graneheim & Lundman, 2004). در زمینه طراحی سیستم پشتیبان تصمیمگیری اعتباری، چنین رویکردی میتواند به شناسایی شاخصهای طلایی اعتبارسنجی، علائم هشداردهنده رفتار مالی، منطق اولویتبندی ریسک و الزامات اعتماد به هوش مصنوعی کمک کند.



بر این اساس، تلفیق روشهای کیفی و کمی در طراحی سیستمهای هوشمند بانکی ضرورتی روششناختی و کاربردی دارد. فاز کیفی میتواند منطق تصمیمگیری کارشناسان را آشکار سازد و فاز کمی میتواند همان منطق را در قالب معماری یادگیری عمیق، دادههای تراکنشی و شاخصهای اعتباری عملیاتی کند. چنین رویکردی از یک سو مانع طراحی مدلهای صرفاً دادهمحور و فاقد معنا برای کاربران نهایی میشود و از سوی دیگر، امکان ارزیابی عینی، تکرارپذیر و مقیاسپذیر سلامت مالی مشتریان را فراهم میکند. به بیان دیگر، سیستم پشتیبان تصمیمگیری مطلوب در بانکداری باید هم از قدرت محاسباتی یادگیری عمیق بهره‌مند باشد و هم با منطق شناختی و تجربی کارشناسان اعتبارسنجی همسو باشد.

با توجه به اهمیت مدیریت ریسک اعتباری، گسترش دادههای دیجیتال مشتریان، محدودیت مدلهای سنتی اعتبارسنجی، ظرفیت مدلهای یادگیری عمیق در تحلیل روندهای پیچیده، ضرورت تبیینپذیری تصمیمات الگوریتمی و ارزش دانش ضمنی کارشناسان بانکی، پژوهش حاضر با هدف طراحی یک سیستم پشتیبان تصمیمگیری هوشمند برای شناسایی سلامت مالی و اولویتبندی مشتریان بانکی بر پایه تلفیق دانش تخصصی کارشناسان اعتبارسنجی با مدلهای یادگیری عمیق گروهی انجام شد.

روش پژوهش

پژوهش حاضر با هدف طراحی یک سیستم پشتیبان تصمیمگیری هوشمند برای تشخیص سلامت مالی مشتریان بانکی، از رویکرد آمیخته از نوع اکتشافی- متوالی بهره گرفته است. این رویکرد به پژوهشگر اجازه میدهد تا ابتدا با استفاده از روشهای کیفی، درک عمیقی از پدیده مورد مطالعه پیدا کرده و سپس با بهره‌گیری از روشهای کمی، مدلی مبتنی بر همان درک عمیق توسعه دهد. بدین منظور، پژوهش در دو فاز کیفی و کمی طراحی و اجرا شد. در فاز کیفی، جامعه آماری شامل متخصصان و کارشناسان ارشد اعتبارسنجی و مدیریت ریسک اعتباری شاغل در دپارتمانهای اعتبارات، ریسک و بازاریابی بانکهای تجاری و تخصصی شهر تهران بودند. برای انتخاب مشارکتکنندگان، از روش نمونهگیری هدفمند با حداکثر تنوع از نظر سابقه کار، جنسیت، نوع بانک و حوزه تخصصی استفاده شد. حجم نمونه بر اساس اصل اشباع نظری تعیین گردید و پس از انجام ۱۶ مصاحبه، اشباع حاصل شد. ملاکهای ورود به مطالعه شامل داشتن حداقل ۳ سال سابقه کار مستمر در حوزه اعتبارسنجی یا مدیریت ریسک بانکی و اعلام تمایل آگاهانه به مشارکت بود. ابزار گردآوری دادهها، مصاحبه نیمهساختاریافته عمیق با استفاده از یک راهنمای مصاحبه بود که روایی محتوایی آن توسط سه متخصص بانکی تأیید شد. مصاحبهها در محیطی آرام و خارج از ساعات اداری برگزار گردید، ضبط و سپس کلمه‌به‌کلمه پیاده‌سازی شدند. برای تحلیل دادههای کیفی، از رویکرد تحلیل محتوای قراردادی گرانیم و لوندمن^۱ (۲۰۰۴) شامل کدگذاری باز، طبقه‌بندی در طبقات فرعی و انتزاع مؤلفه‌های اصلی استفاده شد. این فرآیند با بهره‌گیری از نرم‌افزار MAXQDA 2022 انجام گردید و اعتبار یافته‌ها از طریق بازبینی توسط مشارکتکنندگان و ممیزی پژوهشگر مستقل تأمین شد. در فاز کمی، دادههای موجود پروندههای اعتباری و تراکنشی مشتریان حقیقی یک بانک تجاری بزرگ ایرانی به روش سرشماری هدفمند استخراج گردید. ملاکهای ورود شامل سن بالاتر یا مساوی ۲۱ سال، دارا بودن حداقل یک تسهیلات اعتباری فعال با سابقه بازپرداخت حداقل ۱۲ ماه، و تکمیل بودن اطلاعات حساب حداقل ۸۵٪ از فیلدهای الزامی بود. متغیرهای پیشین شامل سه گروه جمعیتشناختی (سن، جنسیت، تحصیلات، نوع شغل و وضعیت تأهل)، سریهای زمانی رفتار مالی (میانگین مانده حساب ماهانه، تعداد تراکنشها، نسبت پوشش اقساط و روزهای تأخیر در بازپرداخت در ۱۲ ماه اخیر) و شاخصهای اعتباری ایستا (نسبت بدهی به درآمد، امتیاز اعتباری، نسبت مانده تسهیلات به ارزش وثیقه، سابقه نکول و تعداد استعلامهای اعتباری) بودند. متغیر پیامد نیز شامل اولویتبندی مشتری در سه کلاس کم‌ریسک، پرریسک و بحرانی بر اساس

¹ Graneheim, & Lundman

یافته‌های فاز کیفی بود. برای استخراج و مدیریت داده‌ها از PostgreSQL و برای مدلسازی از پایتون با کتابخانه‌های PyTorch، Scikit-learn و پاندا استفاده شد. برای توسعه مدل، داده‌ها به صورت تصادفی به سه بخش آموزش (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمون (۱۵٪) تقسیم شدند. با توجه به ناهمگنی داده‌های مشتریان، یک معماری ترکیبی سه‌شاخه‌ای طراحی گردید: شاخه اول با استفاده از شبکه LSTM دوطرفه به تحلیل روند رفتار مالی در پنجره ۱۲ ماهه می‌پردازد تا الگوهای پویای رفتار مشتری را شناسایی کند. شاخه دوم با شبکه عصبی تماماً متصل، شاخصهای اعتباری ایستا را پردازش مینماید و شاخه سوم نیز متغیرهای جمعیتشناختی را تحلیل میکند. در نهایت، خروجی این سه شاخه در یک لایه تلفیق ادغام شده و تصمیم نهایی درباره کلاس ریسک مشتری اتخاذ میگردد. برای آموزش مدل از بهینه‌ساز AdamW و مکانیسم توقف زودهنگام استفاده شد تا از بیشبرازش جلوگیری گردد. ارزیابی عملکرد مدل بر روی مجموعه آزمون با معیارهای AUC-ROC، Precision، Recall، F1-Score و ماتریس درهم‌ریختگی انجام شد. همچنین برای تبیین پذیری و شناسایی متغیرهای تأثیرگذار، از تحلیل SHAP استفاده گردید و نتایج آن با اولویت‌های استخراج‌شده از فاز کیفی در یک ماتریس مثلث‌سازی مقایسه شد تا میزان همگرایی مدل با دانش ضمنی کارشناسان بررسی گردد. متغیرهای پژوهش به دو بخش متغیرهای پیشبین و متغیر پیامد تقسیم میشوند. جدول شماره (۱) متغیرهای پیشبین را نشان میدهد:

جدول ۱

متغیرهای پیشبین

گروه	متغیرها
جمعیتشناختی	سن، جنسیت، سطح تحصیلات، نوع شغل، وضعیت تأهل
سریهای زمانی (رفتار مالی)	میانگین مانده حساب ماهانه، تعداد تراکنشهای ورودی/خروجی، نسبت پوشش اقساط، تعداد روزهای تأخیر در بازپرداخت (ثبت ماهانه ۱۲ ماه اخیر)
شاخصهای اعتباری	نسبت بدهی به درآمد (DTI)، امتیاز اعتباری (Credit Score)، نسبت مانده تسهیلات به ارزش وثیقه (LTV)، سابقه نکول قبلی، تعداد استعلامهای اعتباری

متغیر پیامد، اولویت‌بندی مشتری در سه کلاس سلامت مالی: کم‌ریسک (سالم)، پرریسک (نیازمند پایش)، بحرانی (در آستانه نکول) تعریف شده بر اساس یافته‌های فاز کیفی میباشد.

یافته‌ها

بخش کیفی این پژوهش از طریق ۱۶ مصاحبه نیمه‌ساختاریافته با متخصصان اعتبارسنجی و مدیریت ریسک بانکی انجام گردید. مشارکت‌کنندگان دارای میانگین سنی $۸/۶ \pm ۴۵/۲$ سال و میانگین سابقه کار بانکی $۴/۷ \pm ۱۲/۳$ سال بودند که نشان‌دهنده تنوع مناسب در سطوح تجربی و برخوردار از دانش عمیق عملیاتی در حوزه اعتبارسنجی میباشد. تحلیل نظام‌مند داده‌های حاصل از مصاحبه‌ها با رویکرد تحلیل محتوای قراردادی گرانیب و لوندمن (۲۰۰۴)، به استخراج ۴۸۷ کد اولیه، ۱۸ طبقه فرعی و در نهایت ۵ مؤلفه اصلی منجر گردید که چارچوب مفهومی سیستم پشتیبان تصمیم‌گیری را شکل میدهند. جدول (۲) مؤلفه‌های اصلی استخراج‌شده از تحلیل محتوای کیفی و مفاهیم کلیدی آنها را نشان میدهد:



مؤلفه‌های اصلی استخراج‌شده از تحلیل محتوای کیفی و مفاهیم کلیدی آنها

مؤلفه اصلی	فراوانی کدها	طبقات فرعی عمده	کاربرد در طراحی DSS
شاخصهای اعتبارسنجی	۱۱۲	نسبت بدهی به درآمد (DTI)، امتیاز اعتباری ^۱ ، نسبت مانده تسهیلات به ارزش وثیقه (LTV)، سابقه نکول قبلی	تعریف متغیرهای وروری ایستا (شاخه دوم شبکه)
علائم هشداردهنده رفتار مالی	۹۸	روند کاهشی میانگین مانده حساب، افزایش تعداد روزهای تأخیر، کاهش نسبت پوشش اقساط، افزایش دفعات استعمال اعتباری	تعریف سریهای زمانی برای شاخه LSTM مدل
الگوریتم ذهنی اولویتبندی ریسک	۸۹	طبقه‌بندی به سه گروه: کم‌ریسک (سالم)، پریسک (نیازمند پایش)، بحرانی (در آستانه نکول) بر اساس ترکیب شاخصهای ایستا و روندهای زمانی	تعریف متغیر پیامد به صورت سه‌کلاس
موانع تصمیمگیری اعتباری	۷۴	داده‌های پراکنده در سامانه‌های مختلف، عدم وجود نمای یکپارچه از رفتار مالی مشتری، خطای انسانی در محاسبات دستی، فشار زمانی برای تصمیمگیری	توجیه ضرورت DSS و نیاز به یکپارچه‌سازی چندوجهی داده‌ها
الزامات اعتماد به هوش مصنوعی در بانکداری	۱۱۴	نیاز به نمایش دلایل تصمیم، وزندهی به متغیرها، رابط کاربری ساده با کدگذاری رنگی (چراغ راهنمایی)، قابلیت ردیابی علت رد یا تأیید تسهیلات	تعیین استراتژی تبیینپذیری (SHAP) و طراحی رابط کاربری

با توجه به جدول (۲) مهمترین یافته این فاز، اتفاقنظر مشارکتکنندگان بر سه‌گانه «نسبت بدهی به درآمد، روند پوشش اقساط و امتیاز اعتباری» به‌عنوان هسته اصلی تصمیمگیری در فرآیند اعتبارسنجی است. به‌بیان دقیقتر، مشارکتکنندگان بر این باور بودند که اگرچه هر یک از این شاخصها به‌تنهایی حائز اهمیت هستند، اما همبستگی و تأثیر متقابل آنها بر یکدیگر است که تصویر واقعیت‌تری از وضعیت سلامت مالی مشتری ارائه می‌دهد. علاوه بر این، مشارکتکنندگان به‌طور شفاف بر مفهوم اولویتبندی سه‌سطحی (کم‌ریسک، پریسک، بحرانی) به‌عنوان یک نیاز عملیاتی اصلی برای DSS تأکید داشتند. به‌عبارتی، آنها طبقه‌بندی صرفاً دوگانه را برای مدیریت پویای پرتفوی اعتباری ناکافی دانسته و بر ضرورت تفکیک مشتریان پریسک از بحرانی تأکید می‌ورزیدند تا بتوان برای هر گروه، استراتژیهای پیشگیرانه یا درمانی متناسب طراحی نمود. این طبقات، پایه و اساس تعریف متغیر پیامد در فاز کمی پژوهش را تشکیل دادند. از سوی دیگر، کارشناسان بهداشت بر قابلیت ردیابی علت تصمیم^۲ تأکید داشتند و تمایل نداشتند از یک جعبه‌سیاه پیروی کنند. به‌بیان یکی از مشارکتکنندگان با سابقه بالا ما باید بتوانیم به مشتری یا مدیران توضیح دهیم که چرا این تصمیم را گرفته‌ایم. اگر سیستمی نتواند دلیل رد یا تأیید را نشان دهد، هرچقدر هم دقیق باشد، قابل اعتماد نیست.» این الزام، ضرورت استفاده از روشهای تبیینپذیری مانند SHAP را در فاز کمی به‌خوبی توجیه مینماید.

در بخش کمی پس از استخراج کوهورت بر اساس ملاکهای ورود از پایگاه داده بانک، مجموعاً ۴۸۷۲ پرونده اعتباری واجد شرایط شناسایی شد. متغیر پیامد (اولویتبندی سه‌کلاس) بر اساس پروکسیهای مالی تعریف‌شده در فاز کیفی، توسط دو کارشناس ارشد اعتبارسنجی نشانگذاری گردید. داده‌ها به سه بخش آموزش (۷۰٪، $n=3410$)، اعتبارسنجی (۱۵٪، $n=731$) و آزمون (۱۵٪، $n=731$) تقسیم شدند که بخش اعتبارسنجی به‌عنوان مجموعه‌های مستقل برای تنظیم فرآیندها و نظارت بر عملکرد مدل در طول فرآیند آموزش در نظر گرفته شد.

^۱ Credit Score^۲ Traceability

مدل ترکیبی سهشاخه‌ای (LSTM دوطرفه + شبکه‌های کاملاً متصل) به مدت ۱۵۰ اپوک آموزش داده شد و فرآیند توقف زودهنگام^۱ در اپوک ۹۸ فعال گردید، به‌گونه‌ای که از آموزش بیش از حد و حفظ‌سازی داده‌ها جلوگیری به عمل آمد. در ادامه عملکرد مدل بر روی مجموعه آزمون با معیارهای تفکیک و طبقه‌بندی اندازه‌گیری شد. جدول (۳) خلاصه‌ای از عملکرد کلی مدل و عملکرد به تفکیک هر کلاس اولویت‌بندی را نشان می‌دهد.

جدول ۳

عملکرد مدل ترکیبی یادگیری عمیق در مجموعه آزمون (۷۳۱) (n=)

AUC-ROC (۹۵% CI)	F1-Score	حساسیت	دقت	کلاس سلامت مالی
۰/۹۷ (۰/۹۵ - ۰/۹۸)	۰/۹۳	۰/۹۴	۰/۹۲	کم‌ریسک
۰/۹۱ (۰/۸۹ - ۰/۹۳)	۰/۸۳	۰/۸۱	۰/۸۵	پرریسک
۰/۸۸ (۰/۸۵ - ۰/۹۱)	۰/۷۶	۰/۷۵	۰/۷۸	بحرانی
۰/۹۳ (۰/۹۱ - ۰/۹۵)	۰/۸۶	۰/۸۶	۰/۸۷	میانگین وزنی

نتایج ارائه‌شده در جدول (۳) نشان‌دهنده عملکرد بسیار مطلوب مدل در شناسایی و تأیید مشتریان کم‌ریسک با F1-Score معادل ۰/۹۳ است که حکایت از توانایی بالای مدل در رد کردن موارد سالم و در نتیجه کاهش چشمگیر هشدارهای کاذب دارد؛ این ویژگی از منظر عملیاتی حائز اهمیت است، زیرا کاهش هشدارهای کاذب به معنای صرفه‌جویی در زمان و هزینه کارشناسان برای بررسی موارد غیرضروری می‌باشد. حساسیت ۸۱٪ برای کلاس پرریسک نشان می‌دهد که مدل قادر است بخش عمده‌ای از مشتریان در معرض خطر را پیش از ورود به مرحله بحرانی شناسایی نماید و این امر امکان مداخلات پیشگیرانه بهموقع را برای بانک فراهم می‌آورد. گرچه عملکرد مدل در کلاس بحرانی با F1-Score معادل ۰/۷۶ پایینترین مقدار را به خود اختصاص داده است، اما با عنایت به ناهمگونی ذاتی و پیچیدگی رفتاری مشتریان بحرانی که اغلب الگوهای غیرخطی و غیرقابل‌پیش‌بینی از خود نشان می‌دهند، این سطح از عملکرد از منظر عملیاتی همچنان قابل قبول ارزیابی می‌گردد. مقدار AUC-ROC کلی معادل ۰/۹۳ به‌وضوح نشان‌دهنده قدرت تفکیک‌کنندگی عالی مدل در تمایز میان سه کلاس ریسک می‌باشد و برازش مناسبی را با داده‌های آزمون تأیید مینماید.

در مرحله تحلیل تبیین‌پذیری و اهمیت ویژگی‌ها صورت گرفت و برای گشودن "جعبه سیاه" مدل، تحلیل SHAP بر روی مجموعه آزمون اجرا شد. جدول (۴)، پنج ویژگی برتر را به همراه تفسیر مالی تأثیر آنها ارائه می‌دهد:

^۱ Early Stopping



پنج ویژگی برتر بر اساس میانگین قدر مطلق مقادیر SHAP و تفسیر مالی تأثیر آنها بر پیشبینی کلاس بحرانی

رتبه	ویژگی	میانگین SHAP	تأثیر بر اساس مدل
۱	آخرین مقدار نسبت بدهی به درآمد	۰/۴۵	قویترین سیگنال برای طبقه‌بندی مشتری به عنوان بحرانی. افزایش شدید DTI نشاندهنده فشار بالای تعهدات نسبت به درآمد و ناتوانی قریبالوقوع در بازپرداخت است.
۲	روند نسبت پوشش اقساط (شیب ۶ ماه اخیر)	۰/۳۸۱	دومین عامل مهم. کاهش پیوسته و سریع پوشش اقساط، هشداردهنده کاهش قدرت بازپرداخت و نکول قریبالوقوع است.
۳	امتیاز اعتباری (حداقل ۱۲ ماه اخیر)	۰/۳۱۹	افت امتیاز اعتباری به زیر آستانه بحرانی، وزن بالایی در پیشبینی نکول داشت.
۴	تعداد روزهای تأخیر در ۳ ماه اخیر	۰/۲۹۵	افزایش همزمان تعداد روزهای تأخیر با افزایش DTI، احتمال نکول را تشدید میکند.
۵	میانگین مانده حساب (کمینه ۳ ماه اخیر)	۰/۲۶۸	کاهش شدید میانگین مانده حساب (تخلیه حساب)، نشانهای از خروج منابع و پیشدرآمد نکول تلقی گردید.

برجسته‌ترین یافته‌ی حاصل از تحلیل SHAP، همگرایی چشمگیر میان ۵ ویژگی برتر شناسایی‌شده توسط مدل و مؤلفه‌های اصلی مستخرج از فاز کیفی پژوهش است. این همراستایی که در جدول (۴) به‌روشنی قابل مشاهده است، حاکی از آن است که مدل یادگیری عمیق، به‌طور مستقل از قضاوت‌های انسانی و صرفاً مبتنی بر الگوهای نهفته در داده‌های خام، به همان مؤلفه‌هایی وزن داده است که متخصصان بانکی در فرآیند تصمیم‌گیری خود بر آنها تأکید می‌ورزند. این تطابق، نه تنها اعتبار سازه‌های مفهومی تعریف‌شده در پژوهش را تأیید مینماید، بلکه نشاندهنده قابلیت بالای مدل در کشف ساختارهای معنادار از دل داده‌های پیچیده بانکی بدون نیاز به اعمال پیشفرض‌های انسانی است. به عبارت دیگر، مدل توانسته است به‌طور خودکار و مبتنی بر داده، همان الگوهای تشخیصی را بیاموزد که کارشناسان انسانی طی سالها تجربه عملی به آنها دست یافته‌اند.

در نهایت جهت یکپارچه‌سازی نظاممند یافته‌های دو فاز کیفی و کمی از روش مثلث‌سازی استفاده گردید. جدول (۵)، چگونگی مثلث‌سازی یافته‌ها را ارائه می‌دهد:

جدول ۵

ماتریس مثلث‌سازی جهت تطبیق یافته‌های کیفی با یافته‌های کمی

هدف مطالعه	یافته فاز کمی (خروجی مدل عمیق)	یافته فاز کیفی (دیدگاه کارشناسان بانکی)	وضعیت تطبیق
شناسایی ورودیها	وزن SHAP این سه متغیر مجموعاً ۶۰٪ از قدرت پیشبینی مدل را تشکیل دادند.	DTI، روند پوشش اقساط و امتیاز اعتباری، پارامترهای اصلی هستند.	همگرایی کامل
تعریف خروجی	مدل توانست با $AUC=0.93$ این سه کلاس را تفکیک کند.	نیاز به اولویت‌بندی سه سطحی (کم‌ریسک، پرمیسک، بحرانی) وجود دارد.	همگرایی عملیاتی
ارزش یک متغیر خاص	سن در رتبه ۱۲ اهمیت SHAP قرار گرفت و وزن مستقل آن ناچیز بود.	نقش "سن" در اعتبارسنجی اولیه کم‌رنگ و تابع شرایط کلی مالی مشتری عنوان شد.	همگرایی ضمنی
نیاز پنهان	شاخه LSTM به تنهایی ۲۳٪ قدرت پیشبینی بیشتری نسبت به مدل پایه استاتیک داشت.	کارشناسان بر اندازه‌گیری "روند" به جای "مقادیر مطلق" تأکید داشتند.	کمی‌سازی یک نیاز کیفی

همانطور که در جدول (۵) مشاهده میشود، فرآیند مثلثسازی، اعتبار عملیاتی سیستم طراحی شده را بهطور مستحکم مورد پشتیبانی قرار میدهد. همگرایی چشمگیر میان دو منبع مستقل دانش - یکی برخاسته از تجارب زیست‌های کارشناسان انسانی و دیگری حاصل از یادگیری ماشین مبتنی بر داده‌های خام - حاکی از آن است که مدل مفهومی تدوین شده نه تنها از دقت آماری مطلوبی برخوردار است، بلکه از حیث عملیاتی نیز دارای معنا و قابلیت اعتماد میباشد. به بیان روشنتر، این همگرایی نشان میدهد که مدل بهجای یادگیری الگوهای تصادفی یا ساختگی، بهدرستی موفق به کشف روابط علی و ساختارهای بنیادین حاکم بر تصمیمگیری اعتباری شده است.

بحث و نتیجه‌گیری

پژوهش حاضر با هدف طراحی یک سیستم پشتیبان تصمیمگیری هوشمند برای شناسایی سلامت مالی و اولویتبندی مشتریان بانکی بر اساس تلفیق دانش تخصصی کارشناسان اعتبارسنجی با مدل‌های یادگیری عمیق گروهی انجام شد. نتایج بهدست آمده نشان داد که رویکرد آمیخته اکتشافی - متوالی توانسته است از یکسو منطق تجربی و دانش ضمنی متخصصان بانکی را استخراج کند و از سوی دیگر، همان منطق را در قالب یک معماری محاسباتی سهشاخه بهصورت عملیاتی پیاده‌سازی نماید. در فاز کیفی، پنج مؤلفه اصلی شامل شاخصهای طلایی اعتبارسنجی، علائم هشداردهنده رفتار مالی، الگوریتم ذهنی اولویتبندی ریسک، موانع تصمیمگیری اعتباری و الزامات اعتماد به هوش مصنوعی در بانکداری شناسایی شد. در فاز کمی نیز مدل ترکیبی متشکل از شاخه LSTM دوطرفه برای تحلیل روندهای ۱۲ ماهه رفتار مالی، شاخه پردازش شاخصهای اعتباری ایستا و شاخه پردازش متغیرهای جمعیتشناختی توانست مشتریان را در سه سطح کم‌ریسک، پرریسک و بحرانی با ROC-AUC میانگین ۹۳/۰ و F1-Score وزنی ۸۶/۰ طبقه‌بندی کند. این یافته نشان میدهد که طراحی یک سامانه هوشمند اعتبارسنجی زمانی بیشترین کارایی را دارد که داده‌های عددی، روندهای رفتاری و منطق تصمیمگیری کارشناسان در یک چارچوب یکپارچه ترکیب شوند. نخستین یافته مهم پژوهش، عملکرد مطلوب مدل ترکیبی در تفکیک مشتریان بانکی بر اساس سطح سلامت مالی بود. مقدار ROC-AUC میانگین ۹۳/۰ بیانگر قدرت تفکیکنندگی بالای مدل در تشخیص مرز میان مشتریان کم‌ریسک، پرریسک و بحرانی است. همچنین، F1-Score برابر با ۹۳/۰ برای مشتریان کم‌ریسک نشان داد که مدل در شناسایی مشتریان سالم و کاهش هشدارهای کاذب عملکرد بسیار مناسبی داشته است. این موضوع از منظر عملیاتی اهمیت فراوانی دارد؛ زیرا در محیطهای بانکی، ارجاع بیش از حد مشتریان سالم به فرایندهای پایش یا محدودسازی اعتباری میتواند هزینه‌های عملیاتی، نارضایتی مشتری و اختلال در فرایند اعطای تسهیلات را افزایش دهد. این نتیجه با ادبیات گسترده اعتبارسنجی که بر ضرورت بهبود دقت مدل‌های پیشبینی ریسک و کاهش خطای طبقه‌بندی در تصمیمات اعتباری تأکید دارد، همسو است (Dastile et al., 2020). همچنین، یافته حاضر با مطالعاتی همراستا است که نشان داده‌اند مدل‌های یادگیری ماشین و یادگیری عمیق میتوانند در پیشبینی ریسکهای بانکی و تشخیص الگوهای پنهان ناتوانی مالی نسبت به روشهای سنتی کارآمدتر باشند (Gunnarsson et al., 2021; Petropoulos et al., 2020).

نتایج مربوط به عملکرد مدل در کلاسهای پرریسک و بحرانی نیز از نظر مدیریتی قابل توجه است. مدل برای مشتریان پرریسک به F1-Score برابر با ۸۳/۰ و برای مشتریان بحرانی به F1-Score برابر با ۷۶/۰ دست یافت. اگرچه عملکرد مدل در کلاس بحرانی نسبت به دو کلاس دیگر پایینتر بود، اما این کاهش را میتوان با ماهیت پیچیده، ناهمگون و گاه غیرخطی رفتار مشتریان در آستانه نکول توضیح داد. مشتریان بحرانی معمولاً الگوهای مالی ناپایدار، تغییرات ناگهانی در جریان نقدی، تأخیرهای متناوب، افت مانده حساب و افزایش فشار بدهی را بهصورت همزمان تجربه میکنند؛ بنابراین، تفکیک دقیق آنان از مشتریان پرریسک به سطح بالاتری از حساسیت مدل و داده‌های غنیتر نیاز دارد. این یافته با پژوهشهایی همخوان است که نشان داده‌اند در پیشبینی ریسک اعتباری، کلاسهای پرخطر و نادر معمولاً به دلیل عدم توازن



داده‌ها، رفتارهای غیرمعمول و پیچیدگی روابط میان متغیرها دشوارتر از کلاسهای عادی طبقه‌بندی میشوند (Gicic & Subasi, 2023; Sadhwani et al., 2021). با این حال، دستیابی به FI-Score بالاتر از ۷۵/۰ در کلاس بحرانی نشان میدهد که مدل پیشنهادی میتواند به‌عنوان ابزار هشدار زودهنگام برای حمایت از تصمیمات کارشناسان اعتبارسنجی مورد استفاده قرار گیرد.

دومین یافته مهم پژوهش، نقش تعیین‌کننده روندهای زمانی رفتار مالی در ارتقای عملکرد مدل بود. نتایج نشان داد که شاخه LSTM بهترین یافته ۲۳/۰ بهبود عملکرد نسبت به مدل ایستای پایه ایجاد کرده است. این نتیجه نشان میدهد که سلامت مالی مشتریان را نمیتوان صرفاً با شاخصهای مقطعی و ثابت سنجید، بلکه تغییرات تدریجی و الگوهای زمانی رفتار مالی نقش اساسی در تشخیص ریسک واقعی دارند. کاهش تدریجی نسبت پوشش اقساط، افزایش تعداد روزهای تأخیر، افت میانگین مانده حساب و تغییرات الگوی تراکنشها، همگی نشانهایی هستند که در یک نگاه ایستا ممکن است نادیده گرفته شوند، اما در تحلیل سریهای زمانی میتوانند به‌عنوان علائم هشداردهنده عمل کنند. این یافته با مبانی نظری یادگیری عمیق در مالی همسو است؛ زیرا مدل‌های عمیق، به‌ویژه شبکه‌های حافظه‌دار، توانایی بالایی در استخراج وابستگیهای زمانی و روابط غیرخطی از داده‌های مالی دارند (Heaton et al., 2017, 2021). همچنین، نتایج حاضر با مطالعات ریسک اعتباری مبتنی بر شبکه‌های عمیق هماهنگ است که نشان داده‌اند تحلیل روندهای بازپرداخت و رفتار مالی میتواند نسبت به مدل‌های کاملاً ایستا، قدرت پیشبینی بالاتری ایجاد کند (Gunnarsson et al., 2021; Sadhwani et al., 2021).

سومین یافته برجسته پژوهش، همگرایی میان دانش ضمنی کارشناسان بانکی و نتایج تبیین‌پذیری مدل بود. تحلیل SHAP نشان داد سه متغیر نسبت بدهی به درآمد، روند نسبت پوشش اقساط و امتیاز اعتباری در مجموع حدود ۶۰ درصد از قدرت پیشبینی مدل را تشکیل داده‌اند. همین سه‌گانه در فاز کیفی نیز از سوی مشارکت‌کنندگان به‌عنوان هسته اصلی تصمیمگیری اعتباری شناسایی شد. این همگرایی از نظر نظری و عملی اهمیت زیادی دارد؛ زیرا نشان میدهد مدل عمیق نهنها به دقت آماری بالا دست یافته، بلکه الگوهایی را یاد گرفته است که با منطق تصمیمگیری کارشناسان انسانی همسو هستند. چنین نتایجی با ادبیات مدیریت دانش ضمنی در بانکداری قابل تبیین است؛ زیرا بخش مهمی از تصمیمگیریهای اعتباری مبتنی بر تجربه، شهود حرفهای، نشانهای هشداردهنده و قواعد غیررسمی کارشناسان است (Alahmari et al., 2023). به بیان دیگر، مدل پیشنهادی توانسته است بخشی از خرد تجربی کارشناسان را در قالب وزنه‌های محاسباتی و اهمیت ویژگیها بازنمایی کند.

این همگرایی همچنین پاسخ مستقیمی به یکی از چالشهای اصلی کاربرد هوش مصنوعی در بانکداری، یعنی مسئله اعتماد و تبیین‌پذیری است. در محیطهای بانکی، تصمیمات اعتباری به دلیل پیامدهای مالی، حقوقی و اعتباری نمیتوانند صرفاً بر خروجی یک مدل جعبه‌سیاه متکی باشند. کارشناسان و مدیران باید بدانند که هر تصمیم بر اساس کدام متغیرها و با چه منطقی اتخاذ شده است. یافته‌های پژوهش حاضر نشان داد که استفاده از تحلیل SHAP میتواند منطق تصمیمگیری مدل را تا حد قابل قبولی آشکار کند و به کارشناسان امکان دهد که خروجی مدل را با تجربه حرفهای خود مقایسه کنند. این نتیجه با ادبیات هوش مصنوعی تبیین‌پذیر کاملاً همسو است؛ زیرا تبیین‌پذیری یکی از شروط اساسی اعتماد، پذیرش و مسئولیت‌پذیری در سیستمهای هوشمند محسوب میشود (Arrieta et al., 2020). همچنین، با پژوهشهایی سازگار است که بر ضرورت توضیح‌پذیر کردن پیشبینیهای مبتنی بر یادگیری عمیق در اعتبارسنجی تأکید کرده‌اند (Dastile & Celik, 2021).

یافته‌های کیفی پژوهش نیز نشان داد که متخصصان بانکی صرفاً به دقت مدل توجه ندارند، بلکه قابلیت ردیابی علت تصمیم، نمایش وزن متغیرها، رابط کاربری ساده، و امکان فهم خروجی مدل را از الزامات اعتماد به هوش مصنوعی میدانند. این نتیجه نشان میدهد که پیاده‌سازی موفق سیستمهای پشتیبان تصمیمگیری در بانکداری نیازمند طراحی انسان‌محور است. سامانه‌های که تنها خروجی نهایی را اعلام

کند، حتی اگر دقت بالایی داشته باشد، ممکن است با مقاومت کارشناسان مواجه شود؛ اما سامانه‌های که دلایل تصمیم، روندهای هشداردهنده و شاخصهای مؤثر را به‌صورت شفاف نمایش دهد، میتواند نقش دستیار هوشمند را ایفا کند. این یافته با مطالعات جدید حوزه رفتار مشتری و تحول دیجیتال بانکی نیز قابل ارتباط است؛ زیرا نظام بانکی معاصر در حال حرکت به سمت تصمیمگیری داده‌محور، تعامل دیجیتال و شناخت دقیقتر رفتار مشتریان است (Maziriri et al., 2026; Shafiei et al., 2025). بنابراین، سیستمهای هوشمند آینده باید علاوه بر دقت فنی، با نیازهای ادراکی و تصمیمگیری کاربران سازمانی نیز هماهنگ باشند.

از سوی دیگر، نتایج پژوهش حاضر با مطالعات مربوط به بخشبندی مشتریان و راهبردهای بازاریابی بانکی نیز همخوانی دارد. طبقهبندی سه‌سطحی مشتریان به کم‌ریسک، پرریسک و بحرانی، صرفاً یک خروجی فنی نیست، بلکه میتواند مبنایی برای طراحی راهبردهای متفاوت مدیریت مشتری باشد. مشتریان کم‌ریسک میتوانند مشمول تسهیلات سریعتر، نرخهای ترجیحی یا پیشنهادهای توسعه رابطه بانکی شوند؛ مشتریان پرریسک نیازمند پایش، مشاوره مالی و بازتنظیم شرایط اعتباری هستند؛ و مشتریان بحرانی باید در اولویت مداخلات پیشگیرانه، بازسازی بدهی یا محدودسازی ریسک قرار گیرند. این منطق با پژوهشهایی همسو است که بر اهمیت بخشبندی هوشمند مشتریان بانکی برای تدوین راهبردهای بازاریابی و مدیریت رابطه با مشتری تأکید کرده‌اند (Yan et al., 2025). همچنین، از منظر برندسازی و درگیری مشتری، تصمیمات اعتباری منصفانه، شفاف و متناسب با وضعیت واقعی مشتری میتواند به بهبود تجربه مشتری و تقویت اعتماد به بانک کمک کند (Shadzaad et al., 2025; Taghipourian, 2026).

از نظر روششناختی، استفاده از رویکرد آمیخته در این پژوهش یکی از نقاط قوت اصلی آن بود. فاز کیفی با استفاده از تحلیل محتوای قراردادی امکان استخراج مؤلفه‌های مفهومی از تجربه کارشناسان را فراهم کرد و فاز کمی همان مؤلفهها را در قالب متغیرهای قابل مدلسازی و معماری یادگیری عمیق عملیاتی نمود. این فرایند نشان میدهد که تحلیل کیفی میتواند نقش مهمی در طراحی مدل‌های هوشمند ایفا کند، به‌ویژه زمانی که هدف، ساخت سامانه‌های کاربردی و قابل پذیرش در محیط واقعی است. اعتبار روش کیفی نیز از طریق کدگذاری نظاممند، استخراج طبقات و شکلهای مؤلفه‌های اصلی قابل دفاع است و با اصول تحلیل محتوای کیفی همخوانی دارد (Graneheim & Lundman, 2004). افزون بر این، ترکیب داده‌های کیفی و کمی سبب شد مدل نهایی صرفاً یک الگوریتم پیشبینی نباشد، بلکه به یک سیستم پشتیبان تصمیمگیری مبتنی بر دانش تخصصی تبدیل شود.

در مجموع، یافته‌های پژوهش حاضر نشان میدهد که ادغام دانش ضمنی کارشناسان بانکی با مدل‌های یادگیری عمیق گروهی میتواند مسیر تازه‌ای برای طراحی سیستمهای هوشمند اعتبارسنجی فراهم کند. این رویکرد از یکسو با نیاز صنعت بانکداری به کاهش ریسک اعتباری، افزایش دقت تصمیمگیری و بهبود سلامت پرتفوی همسو است و از سوی دیگر، با الزامات جدید بانکداری دیجیتال، تحلیل رفتار مشتری، تبیین‌پذیری هوش مصنوعی و تصمیمگیری داده‌محور تناسب دارد. با توجه به نقش بانکها در ثبات اقتصادی و ارتباط مستقیم کیفیت داراییهای بانکی با عملکرد بخش واقعی اقتصاد، توسعه چنین سامانه‌هایی میتواند پیامدهایی فراتر از سطح سازمانی داشته باشد و در بهبود حکمرانی اعتباری، کاهش مطالبات غیرجاری و ارتقای کارایی تخصیص منابع نقش‌آفرین باشد (Berger et al., 2020). بنابراین، مدل پیشنهادی این مطالعه میتواند به‌عنوان الگویی برای نسل جدید سیستمهای پشتیبان تصمیمگیری در بانکداری مطرح شود؛ سیستمهایی که نه جایگزین کارشناسان، بلکه تقویت‌کننده قضاوت حرفه‌ای آنان هستند.

این پژوهش با وجود دستاوردهای نظری و کاربردی، با چند محدودیت همراه بود. نخست، داده‌های کمی از پرونده‌های اعتباری و تراکنشی مشتریان یک بانک تجاری بزرگ ایرانی استخراج شد؛ بنابراین، ساختار پرتفوی، سیاستهای اعتباری، نوع مشتریان و شرایط عملیاتی همان بانک ممکن است بر الگوهای یادگرفته‌شده توسط مدل اثر گذاشته باشد و تعمیم نتایج به سایر بانکها باید با احتیاط انجام شود. دوم،



اگرچه داده‌های ۱۲ ماهه رفتار مالی برای تحلیل روندها استفاده شد، اما برخی تغییرات بلندمدت اقتصادی، شوک‌های تورمی، تغییرات سیاست پولی و رخداد‌های بیرونی ممکن است در بازه‌های زمانی طولانی‌تر بهتر قابل مشاهده باشند. سوم، برچسب‌گذاری متغیر پیامد بر اساس پروکسی‌های مالی و نظر کارشناسان انجام شد و هرچند این روش با منطق عملیاتی بانک همسو بود، اما همچنان امکان وجود سوگیری انسانی یا اختلاف در قضاوت کارشناسان وجود دارد. چهارم، تحلیل SHAP تبیینی از اهمیت ویژگی‌ها ارائه می‌دهد، اما به‌تنهایی اثبات‌کننده رابطه علی میان متغیرها و وضعیت نکول یا سلامت مالی نیست.

پیشنهاد میشود پژوهش‌های آینده مدل پیشنهادی را با استفاده از داده‌های چندبانکی و در محیط‌های اعتباری متنوع اعتبارسنجی کنند تا قابلیت تعمیم و پایداری آن در شرایط مختلف بررسی شود. همچنین، استفاده از داده‌های طولی با بازه‌های زمانی طولانی‌تر میتواند به شناسایی بهتر الگوهای تدریجی زوال سلامت مالی مشتریان کمک کند. پژوهش‌های بعدی میتوانند معماری‌های پیشرفته‌تر مانند مدل‌های مبتنی بر توجه، ترنسفورمرهای زمانی، شبکه‌های گرافی و مدل‌های یادگیری چندوجهی را با معماری پیشنهادی مقایسه کنند. افزون بر این، بررسی نقش داده‌های جایگزین مانند رفتار بانکداری دیجیتال، الگوی تعامل با اپلیکیشن‌های بانکی، رفتار پرداخت‌های خرد و شاخص‌های تجربه مشتری میتواند به توسعه مدل‌های جامع‌تر منجر شود. در نهایت، انجام مطالعات مداخله‌ای یا شبه‌آزمایشی در شعب بانکی پیشنهاد میشود تا اثر واقعی استفاده از این سیستم بر کاهش نکول، بهبود سرعت تصمیم‌گیری و افزایش اعتماد کارشناسان سنجیده شود.

بانک‌ها میتوانند از یافته‌های این پژوهش برای طراحی و پیاده‌سازی سیستم‌های پشتیبان تصمیم‌گیری اعتباری استفاده کنند که علاوه بر ارائه طبقه‌بندی ریسک، دلایل تصمیم را نیز به زبان قابل فهم برای کارشناسان نمایش دهند. پیشنهاد میشود رابط کاربری چنین سامانه‌هایی به‌گونه‌ای طراحی شود که سه سطح کم‌ریسک، پرریسک و بحرانی را با شاخص‌های هشداردهنده، روندهای زمانی و وزن متغیرهای اصلی نشان دهد. همچنین، لازم است استفاده از این مدل‌ها به‌صورت مکمل قضاوت کارشناسان باشد، نه جایگزین کامل آنان؛ زیرا ترکیب تجربه انسانی و تحلیل الگوریتمی میتواند کیفیت تصمیمات را افزایش دهد. بانک‌ها میتوانند برای هر سطح ریسک، پروتکل‌های عملیاتی متفاوتی طراحی کنند؛ برای مثال، مشتریان پرریسک را در مسیر پایش و مشاوره مالی قرار دهند و مشتریان بحرانی را برای اقدامات فوری بازسازی بدهی یا محدودسازی ریسک اولویت‌بندی کنند. آموزش کارشناسان اعتبارسنجی برای تفسیر خروجی‌های مدل و استفاده صحیح از تحلیل‌های تبیین‌پذیر نیز برای پذیرش موفق چنین سامانه‌هایی ضروری است.

تعارض منافع

در انجام مطالعه حاضر، هیچگونه تضاد منافی وجود ندارد.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

موازین اخلاقی

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

شفافیت دادهها

دادهها و مآخذ پژوهش حاضر در صورت درخواست از نویسنده مسئول و ضمن رعایت اصول کپی رایت ارسال خواهد شد.

حامی مالی

این پژوهش حامی مالی نداشته است.

References

- Alahmari, F., Saad, S., & Pileggi, S. F. (2023). A systematic literature review of tacit knowledge management in the banking sector. *Journal of Knowledge Management*, 27(5), 1310-1334.
- Arrieta, A. B., Diaz-Rodriguez, N., Del Ser, J., Benetot, A., Tabik, S., Barbado, A., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Berger, A. N., Molyneux, P., & Wilson, J. O. S. (2020). Banks and the real economy: An assessment of the research. *Journal of Corporate Finance*, 62, 101513. <https://doi.org/10.1016/j.jcorpfin.2019.101513>
- Dastile, X., & Celik, T. (2021). Making deep learning-based predictions for credit scoring explainable. *IEEE Access*, 9, 50426-50440. <https://doi.org/10.1109/ACCESS.2021.3068854>
- Dastile, X., Celik, T., & Potsane, M. (2020). Statistical and machine learning models in credit scoring: A systematic literature review. *Applied Soft Computing*, 91, 106263. <https://doi.org/10.1016/j.asoc.2020.106263>
- Gicic, A., & Subasi, A. (2023). Credit scoring for a microcredit data set using deep learning ensemble methods. *Computing in science & engineering*, 25(2), 20-31.
- Graneheim, U. H., & Lundman, B. (2004). Qualitative content analysis in nursing research: Concepts, procedures and measures to achieve trustworthiness. *Nurse Education Today*, 24(2), 105-112. <https://doi.org/10.1016/j.nedt.2003.10.001>
- Gunnarsson, B. R., Vanden Broucke, S., Baesens, B., Oskarsdottir, M., & Lemahieu, W. (2021). Deep learning for credit scoring: Do or don't? *European Journal of Operational Research*, 295(1), 292-305. <https://doi.org/10.1016/j.ejor.2021.03.006>
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2017). Deep learning for finance: Deep portfolios. *Applied Stochastic Models in Business and Industry*, 33(1), 3-12. <https://doi.org/10.1002/asmb.2209>
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2021). Deep learning in finance: A review. *Journal of Financial Data Science*, 3(2), 10-25.
- Maziriri, E. T., Rukuni, T. F., Nyagadza, B., & Bepe, T. (2026). The customer's quest to manage funds digitally: Exploring the factors that influence the intention to use and the ongoing use of mobile banking apps. *Computers in Human Behavior Reports*, 21, 100907. <https://doi.org/10.1016/j.chbr.2025.100907>
- Petropoulos, A., Siakoulis, V., Stavroulakis, E., & Vlachogiannakis, N. E. (2020). Predicting bank insolvencies using machine learning techniques. *International Journal of Forecasting*, 36(3), 1092-1113. <https://doi.org/10.1016/j.ijforecast.2019.11.005>
- Sadhwani, A., Giesecke, K., & Sirignano, J. (2021). Deep learning for mortgage risk. *Journal of Financial Econometrics*, 19(2), 313-341. <https://doi.org/10.1093/jjfinec/nbaa025>
- Shadad, V., Naami, A., Kimasi, M., & Azad, N. (2025). Designing a digital content marketing model with a customer engagement approach in commercial banks. *Business, Marketing, and Finance Open*, 2(1), 150-160. <https://doi.org/10.61838/bmfopen.2.1.14>
- Shafiei, A. S. M., Taleghani, M., & Haghayegh, R. A. S. (2025). Designing and Validating a Behavioral Model of Banking System Customers. *Management Strategies and Engineering Sciences*, 7(3), 47-56. <https://doi.org/10.61838/msej.7.3.5>
- Taghipourian, M. J. (2026). The role of emotional branding on brand equity in the banking sector: Is customer experience a mediator? *Dynamic Management and Business Analysis*, 1-17. <https://www.dmbaj.com/index.php/dmba/article/view/247>
- Yan, X., Li, Y., Nie, F., & Li, R. (2025). Bank Customer Segmentation and Marketing Strategies Based on Improved DBSCAN Algorithm. *Applied Sciences*, 15(6).