

## Identifying Self-healing Contracts with Machine Learning: Analyzing the Accuracy and Disaggregation of 30 to 90 Day Debts

Mahboob Sadeghi <sup>1</sup>, Ali Saeedi <sup>2\*</sup>, Alireza Heidarzadeh Hanzaeei <sup>3</sup>

1. Department of Management, NT.C., Islamic Azad University, Tehran, Iran.
2. Department of Management, NT.C., Islamic Azad University, Tehran, Iran.
3. Department of Management, NT.C., Islamic Azad University, Tehran, Iran.

### OPEN ACCESS

**Article type:** Research Article

**\*Correspondence:** Ali Saeedi  
a\_saeedi@iau-tnb.ac.ir

**Received:** March 25, 2025

**Accepted:** September 6, 2025

**Published:** Summer 2025

**Citation:** Sadeghi, M., Saeedi, A., Heidarzadeh Hanzaeei, A. (2025). Identifying Self-healing Contracts with Machine Learning: Analyzing the Accuracy and Disaggregation of 30 to 90 Day Debts. *Journal of Management and Sustainable Development Studies*, 5(2), 109-133.

**Publisher's Note:** MSDS stays neutral with regard to jurisdictional claims in published material and institutional affiliations.



**Copyright:** Authors retain the copyright and full publishing rights.

Published by Islamic Azad University of Zahedan. This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

**Abstract:** Forecasting the collection of non-current receivables is one of the key challenges in the financial management of financial and credit institutions. This issue not only affects the financial stability and soundness of banks, but also directly affects their ability to manage risk and determine effective credit strategies. The present study uses artificial intelligence-based methods to provide a forecasting model to determine the probability of collection of non-current receivables in contracts with debt due between 30 and 90 days. In this study, machine learning algorithms, including decision trees, random forests, and model clarification analyses, especially SHAP (SHapley Additive exPlanations), are used to analyze financial data and predict the status of receivables collection. The results of the analysis show that machine learning models are able to distinguish and isolate self-healing contracts from other contracts with considerable accuracy in the future. The findings show that machine learning models have a high power in distinguishing self-healing contracts from other cases. The SHAP tool has also played a key role in analyzing the features that affect the prediction. This approach can be effectively used in improving banks' credit risk management solutions.

**Keywords:** Non-performing Loan Collection Forecasting, Explainable Artificial Intelligence, Machine Learning, SHAP, Feature Analysis.

DOI: [10.71572/msds.2025.1207580](https://doi.org/10.71572/msds.2025.1207580)

## **Extended Abstract**

### **Introduction**

One of the problems facing the banking system of various countries, including Iran, is the increase in past due and overdue claims of banks compared to the total facilities granted in the country's banking network, which indicates a decrease in the quality of the banking network's assets and, consequently, possible financial instability in the future. The existence of such claims has very negative effects on the cycle of resources and expenditures of banks, so that from an internal perspective, operating costs, profitability, customer service, branch grading, employee salaries and benefits, and other quality indicators, branches are severely affected. From an external perspective, it causes a slowdown in the circulation of liquidity in the country's economy, the lack of timely and optimal allocation of resources to the production and industry network as facilities, the lack of employment boom and ultimately economic recession will follow, and the accumulation of overdue claims is increasing concerns day by day. In summary, this research, using new approaches in the field of explainable artificial intelligence, attempts to provide an efficient, accurate, and transparent model for predicting the collection of non-performing loans in banks. The use of machine learning models and analytical tools not only allows for increased accuracy in prediction, but also provides the ability to interpret and clarify model decisions for end users. Such an approach can lead to improving the credit assessment system, enhancing the quality of financial decision-making, and reducing credit risks in the country's banking system.

### **Theoretical framework**

The banking system, as one of the vital pillars of the country's economy, is responsible for mobilizing and allocating financial resources. A significant part of this task is achieved in the form of granting facilities to natural and legal persons. However, granting facilities is always accompanied by risks, the most important of which is the risk of default or non-repayment of facility installments by customers. When customers are unable to pay their installments on the specified due date, the bank's receivables are placed in a non-current state, which, if continued, will not only threaten the bank's profitability but also cause a liquidity crisis and, in extreme cases, threaten economic stability at the macro level. Non-current receivables have become one of the important indicators for assessing the efficiency and health of the banking system in recent years. In order to control this risk, banks and regulatory institutions have always sought tools and models to predict the probability of customer default and analyze the factors affecting the repayment or non-repayment of facilities. In response to these shortcomings, in recent years, artificial intelligence, and especially machine learning, have attracted the attention of researchers and activists in the financial field as new tools for data analysis. Algorithms such as artificial neural networks, decision trees, random forests, support vector machines, and deep learning models have been able to identify complex relationships between customer characteristics and repayment probability by learning from large volumes of historical data and provide highly accurate models (Lessmann et al., 2015 and Zhang et al., 2021). In the meantime, explainable artificial intelligence has emerged as a new approach in data science that aims to increase the transparency, understandability, and reliability of complex machine learning models. XAI includes a set of methods and algorithms that can make the causes and logic of AI models' decisions interpretable to humans. Methods such as LIME, SHAP, Anchors, and feature-based decisions are among the key techniques in this area that have found important applications in banking and credit risk analysis (Barredo Arrieta et al., 2020 and Ribeiro et al., 2016).

## **Methodology**

The present study is applied in terms of purpose and analytical-quantitative in terms of approach, and by using machine learning algorithms and explainable artificial intelligence methods, it seeks to design a model to predict the probability of collection of non-current receivables in contracts with debt due between 30 and 90 days. This research is included in the category of data-driven research that uses real banking and credit data to try to provide an accurate and interpretable model for credit decision-making. Considering the specific characteristics of financial data and the complexity of customer behavior, the research uses a predictive modeling approach to extract and explain the relationships affecting the probability of default and repayment through analyzing the patterns in the data. Given the importance of the issue of collection of receivables in banking processes, always dealing appropriately and systematically with bad-paying customers in order to improve their situation requires predicting and identifying these people with high accuracy and at the right time. Therefore, in order to reduce the operational and human costs of identifying these individuals and also to minimize the dissatisfaction of generally good customers with inappropriate repayment behavior, a high-accuracy intelligent model is needed. With the advancement of artificial intelligence and machine learning algorithms, significant improvements have been achieved in the performance of many different business areas that use data-based artificial intelligence. Therefore, it can be said that the use of data-driven machine learning algorithms, along with high accuracy and speed of execution, can prevent erroneous biases in decision-making. Therefore, in the upcoming research, machine learning-based algorithms are used to identify bad customers with a high probability of worsening their repayment status.

## **Discussion and Results**

In this study, the confusion matrix, which is one of the key tools in the analysis of classification models, was used to evaluate the performance of the non-performing loan collection prediction model. In this analysis, customers are classified into two categories: “good” and “bad” and the main goal of the model is to accurately identify customers who are likely to default in the next three months. The results obtained from the confusion matrix showed that the model was able to correctly identify 84.3 percent of bad customers (True Positive), which indicates the high accuracy of the model in identifying high-risk individuals and is considered very crucial for banks in the credit decision-making process. On the other hand, 63 percent of good customers were also correctly identified by the model (True Negative), which indicates the acceptable performance of the model in identifying individuals who are committed to paying. However, the False Positive rate of about 37% indicates that some good customers are wrongly classified as debtors; this may lead to unfair credit decisions such as rejecting a loan application or increasing interest rates, which may have consequences for customer satisfaction and bank policies. Also, the False Negative rate of about 15.7% means that some debtors are wrongly identified as good customers, which may increase credit risks for the bank. These results indicate that although the overall accuracy of the model is relatively good, there is a need to examine the decision threshold more closely and apply model tuning techniques to optimize the final performance. The threshold value chosen for classification is determined based on AUC curve analysis and plays an important role in balancing the model error rates. Previous research has also emphasized that optimal threshold selection and the use of explainable models in financial decision-making can increase the effectiveness and fairness of credit rating systems (Ribeiro et al., 2016; Lundberg & Lee, 2017). Overall, the findings of this study are consistent with similar studies such as Athey et al. (2019) and Bertsimas et al.

(2020), which have shown that the use of machine learning models combined with explainable AI algorithms can increase forecasting accuracy while making the reasons for model decisions transparent to end users. Finally, to improve the receivables collection forecasting system, it is recommended to optimize the model structure, fine-tune the thresholds, and use explainable analysis tools such as SHAP or LIME to increase the accuracy of the model and strengthen the confidence of decision-makers in its results.

### **Conclusion**

In this study, a model for predicting bad debt collection based on explainable artificial intelligence was presented and evaluated. The main goal of this study was to develop a model that can accurately predict bad debt and at the same time provide decision makers and experts with the ability to interpret and analyze its results. Predicting bad debt collection is one of the important challenges in the field of finance and credit that has a direct impact on risk management and improving the financial position of organizations. In this regard, the use of artificial intelligence techniques, especially machine learning, and explainable tools such as SHAP, in order to analyze the effective features in predicting and interpreting the model is of great importance. In this study, first, data related to bad debt were collected and various features that could affect the forecast were identified. Then, using different machine learning algorithms, models were designed to predict bad debt collection. Next, the performance of these models was analyzed and evaluated, and the results obtained were interpreted in detail using explainable tools such as SHAP.

In this chapter, the results of various predictive model tests are examined. The performance of the models is analyzed from various aspects including accuracy, interpretability, and practical capabilities. Also, the features that have the greatest impact on the prediction of non-current receivables are identified and analyzed. Finally, based on the results of these analyses, suggestions will be made for improving the model, developing its practical applications in the financial and credit industries, and future research directions. Given the increasing importance of using artificial intelligence in financial fields, this research can be considered as an effective step in improving decision-making processes and reducing risks associated with non-current receivables. The main hypothesis of the research is examined and analyzed below.

### **Contribution of authors**

All authors have participated in this research in equal proportion.

### **Ethical approval**

Written informed consent was obtained from the individuals for their anonymized information to be published in this article.

### **Conflict of interest**

No conflicts of interest are declared by the authors.

# مطالعات مدیریت و توسعه پایدار

سال پنجم، شماره دوم، تابستان ۱۴۰۴ - صفحه ۱۳۳-۱۰۹

Homepage: <https://sanad.iau.ir/journal/msds> - eISSN: 2783-4395

## شناسایی قراردادهای خوددرمان شونده با یادگیری ماشین: تحلیل دقت و تفکیک پذیری بدهی های ۳۰ تا ۹۰ روزه

محبوب صادقی<sup>۱</sup>، علی سعیدی<sup>۲\*</sup>، علیرضا حیدرزاده هنزائی<sup>۳</sup> 

۱. گروه مدیریت، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران.
۲. گروه مدیریت، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران.
۳. گروه مدیریت، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران.

**چکیده:** پیش‌بینی وصول مطالبات غیرجاری از جمله چالش‌های کلیدی در مدیریت مالی مؤسسات مالی و اعتباری به شمار می‌آید. این مسأله نه تنها بر پایداری و سلامت مالی بانک‌ها تأثیرگذار است، بلکه به طور مستقیم بر توانایی آن‌ها در مدیریت ریسک و تعیین استراتژی‌های اعتباری مؤثر تأثیر می‌گذارد. پژوهش حاضر به منظور ارائه مدلی پیش‌بینی برای تعیین احتمال وصول مطالبات غیرجاری در قراردادهای با بدهی سررسید شده میان ۳۰ تا ۹۰ روز، از روش‌های مبتنی بر هوش مصنوعی استفاده کرده است. در این تحقیق، الگوریتم‌های یادگیری ماشین، شامل درخت تصمیم‌گیری، جنگل تصادفی و تحلیل‌های شفاف‌سازی مدل، به‌ویژه SHAP (SHapley Additive exPlanations)، برای تحلیل داده‌های مالی و پیش‌بینی وضعیت وصول مطالبات به کار رفته‌اند. نتایج تحلیل‌ها نشان می‌دهند که مدل‌های یادگیری ماشین با دقت قابل توجهی قادر به تفکیک و جداسازی قراردادهای خوددرمان شونده از دیگر قراردادها در آینده هستند. یافته‌ها نشان می‌دهند مدل‌های یادگیری ماشین توان بالایی در تفکیک قراردادهای خوددرمان شونده از دیگر موارد دارند. ابزار SHAP نیز در تحلیل ویژگی‌های مؤثر بر پیش‌بینی نقش کلیدی ایفا کرده است. این رویکرد می‌تواند به‌طور مؤثری در بهبود راهکارهای مدیریت ریسک اعتباری بانک‌ها به کار گرفته شود.

دسترسی آزاد

نوع مقاله: مقاله پژوهشی

نویسنده مسئول: علی سعیدی

[a\\_saeedi@iau-tnb.ac.ir](mailto:a_saeedi@iau-tnb.ac.ir)

تاریخ دریافت: ۱۴۰۴/۰۱/۰۵

تاریخ پذیرش: ۱۴۰۴/۰۶/۱۵

تاریخ انتشار: تابستان ۱۴۰۴

استناد: صادقی، محبوب، سعیدی، علی، حیدرزاده هنزائی، علیرضا. (۱۴۰۴). شناسایی قراردادهای خوددرمان شونده با یادگیری ماشین: تحلیل دقت و تفکیک‌پذیری بدهی‌های ۳۰ تا ۹۰ روزه. فصلنامه مطالعات مدیریت و توسعه پایدار، (۲)۵، ۱۰۹-۱۳۳.

یادداشت ناشر: MSDS در خصوص

ادعاهای قضایی در مطالب منتشر شده و وابستگی‌های سازمانی بی‌طرف می‌ماند.



کپی‌رایت: نویسندگان حق نشر و حقوق کامل انتشار را برای خود محفوظ می‌دارند. منتشر شده توسط دانشگاه آزاد اسلامی واحد زاهدان. این مقاله، یک مقاله با دسترسی آزاد است که تحت مجوز [Creative Commons Attribution 4.0 International \(CC BY\)](https://creativecommons.org/licenses/by/4.0/) منتشر شده است.

DOI: [10.71572/msds.2025.1207580](https://doi.org/10.71572/msds.2025.1207580)

واژگان کلیدی: پیش‌بینی وصول مطالبات غیرجاری، هوش مصنوعی توضیح‌پذیر، یادگیری ماشین، SHAP، تحلیل ویژگی‌ها.

## مقدمه

در دنیای امروز که رقابت در حوزه‌های مالی و اعتباری به شدت افزایش یافته است، مدیریت بهینه ریسک‌های اعتباری یکی از مهم‌ترین دغدغه‌های نهادهای مالی، به‌ویژه بانک‌ها و مؤسسات اعتباری به شمار می‌رود. یکی از جنبه‌های مهم این مدیریت، پیش‌بینی وضعیت وصول مطالبات غیرجاری است؛ چرا که مطالبات معوق و مشکوک‌الوصول نه تنها منجر به کاهش نقدینگی و سودآوری نهادهای مالی می‌شوند، بلکه در صورت افزایش، ثبات و سلامت کل نظام اقتصادی را نیز تهدید می‌کنند. در سال‌های اخیر، بهره‌گیری از روش‌های نوین در علم داده و یادگیری ماشین برای پیش‌بینی ریسک اعتباری و تحلیل وضعیت مالی مشتریان، مورد توجه فراوان قرار گرفته است. مدل‌های پیش‌بینی سنتی با وجود سادگی و تفسیرپذیری، از دقت کافی برای تحلیل الگوهای پیچیده برخوردار نیستند. در مقابل، مدل‌های مبتنی بر هوش مصنوعی، به‌ویژه یادگیری ماشین، امکان شناسایی روابط غیرخطی و الگوهای پنهان در داده‌ها را فراهم می‌سازند. با این حال، یکی از چالش‌های جدی در به‌کارگیری این مدل‌ها، مسئله «توضیح‌پذیری» یا شفافیت نتایج آن‌هاست. در حوزه‌هایی همچون بانکداری که تصمیمات مالی بر مبنای نتایج مدل‌های پیش‌بینی اتخاذ می‌شود، قابلیت توضیح و تبیین خروجی مدل برای مدیران و تصمیم‌گیران اهمیت بسزایی دارد. لذا، استفاده از هوش مصنوعی توضیح‌پذیر Explainable AI یا XAI به عنوان رویکردی نوین، می‌تواند ضمن بهره‌گیری از دقت بالای مدل‌های پیچیده، امکان تفسیرپذیری و اعتماد به نتایج را نیز فراهم آورد.

تحقیق حاضر با هدف ارائه یک مدل پیش‌بینی برای وصول مطالبات غیرجاری، تلاش دارد با ترکیب تکنیک‌های پیشرفته یادگیری ماشین و روش‌های توضیح‌پذیری، الگویی کارآمد، دقیق و شفاف برای تصمیم‌سازی در نظام مالی کشور ارائه دهد. در این راستا، ابتدا مجموعه‌ای از داده‌های مرتبط با تسهیلات و مشتریان اعتباری گردآوری شده و سپس مدل‌های مناسب انتخاب، آموزش و ارزیابی می‌شوند. همچنین، از ابزارها و روش‌های توضیح‌پذیری برای تحلیل علل تصمیم‌گیری مدل استفاده خواهد شد تا خروجی‌ها برای کاربران نهایی قابل درک و اعتماد باشند.

طی دو دهه گذشته، سیستم بانکی در سراسر دنیا در محیط فعالیت خود تغییرات شایان توجهی را تجربه کرده و عوامل خارجی و داخلی متعددی بر ساختار و عملکرد سیستم بانکی تأثیرگذار بوده است. با وجود این، برخلاف تمامی تغییرات، سیستم بانکی همچنان میدان دار اصلی تأمین مالی فعالیت‌های اقتصادی در بسیاری از کشورها، از جمله ایران است و در انتقال منابع از پس‌اندازکنندگان به واحدهای سرمایه‌گذاری، نقش اصلی ایفا می‌کند. جذب منابع از اهداف کلیدی، اساسی و راهبردی بانک‌ها و مؤسسه‌های مالی اعتباری به شمار می‌رود و در ارائه خدمات بانک‌ها نقش ویژه‌ای ایفا می‌کند و شاخص مهمی در ارزیابی موفقیت بانک‌ها محسوب می‌شود. به‌طور کلی، در اقتصادهایی نظیر اقتصاد ایران، که سیستم مالی آن‌ها مبتنی بر بانک است، بانک‌ها سهم عمده‌ای در تجهیز و تخصیص منابع مالی از طریق سپرده‌پذیری و اعطای تسهیلات دارند. از این دیدگاه، رصد اعطای تسهیلات و نحوه بازگشت آن‌ها برای مدیران نظام بانکی و سیاستگذاران اقتصادی از اهمیت ویژه‌ای برخوردار است.

یکی از معضله‌هایی که نظام بانکی کشورهای مختلف، از جمله ایران با آن روبرو است، افزایش مطالبات سررسید گذشته و معوق بانک‌ها نسبت به کل تسهیلات اعطایی در شبکه بانکی کشور است که بیانگر کاهش کیفیت دارایی‌های شبکه بانکی و به تبع آن، بی‌ثباتی‌های مالی احتمالی در آینده است. وجود چنین مطالباتی تأثیرات بسیار منفی در چرخه منابع و مصارف بانک‌ها می‌گذارد، به طوری که از منظر داخلی هزینه‌های عملیاتی، راندمان کاری سودآوری، میزان خدمت به مشتریان، درجه بندی شعب، حقوق و مزایای کارکنان و سایر شاخص‌های کیفی، شعب را به شدت تحت تأثیر خود قرار می‌دهد. از منظر بیرونی موجب کندی چرخش نقدینگی در اقتصاد کشور، عدم اختصاص به موقع و بهینه منابع به شبکه تولید و صنعت به عنوان تسهیلات، عدم رونق اشتغال و در نهایت رکود اقتصادی را بدنبال خواهد داشت و انباشته شدن مطالبات سررسید شده روز به روز نگرانی‌ها را دو چندان می‌کند.

در مجموع، این پژوهش با بهره‌گیری از رویکردهای نوین در حوزه هوش مصنوعی توضیح‌پذیر، تلاش دارد تا الگویی کارآمد، دقیق و شفاف برای پیش‌بینی وصول مطالبات غیرجاری در بانک‌ها ارائه دهد. بهره‌گیری از مدل‌های یادگیری ماشین و ابزارهای تحلیل‌پذیر، نه تنها امکان افزایش دقت در پیش‌بینی را فراهم می‌کند، بلکه قابلیت تفسیر و شفاف‌سازی تصمیمات مدل را نیز برای کاربران نهایی فراهم می‌آورد. چنین رویکردی می‌تواند به بهبود نظام اعتبارسنجی، ارتقاء کیفیت تصمیم‌گیری‌های مالی و کاهش ریسک‌های اعتباری در نظام بانکی کشور منجر شود.

### مبانی نظری و پیشینه پژوهش

نظام بانکی به‌عنوان یکی از ارکان حیاتی اقتصاد کشور، وظیفه تجهیز و تخصیص منابع مالی را بر عهده دارد. بخش قابل توجهی از این وظیفه در قالب اعطای تسهیلات به اشخاص حقیقی و حقوقی محقق می‌شود. با این حال، اعطای تسهیلات همواره با ریسک‌هایی همراه است که مهم‌ترین آن، ریسک نکول یا بازپرداخت نشدن اقساط تسهیلات از سوی مشتریان است. هنگامی که مشتریان قادر به پرداخت اقساط خود در سررسید تعیین شده نباشند، مطالبات بانک در وضعیت غیرجاری قرار می‌گیرد که در صورت تداوم، نه تنها سودآوری بانک را تهدید می‌کند، بلکه موجب بحران نقدینگی و در موارد حاد، تهدید ثبات اقتصادی در سطح کلان خواهد شد.

مطالبات غیرجاری<sup>۱</sup> در سال‌های اخیر به یکی از شاخص‌های مهم برای ارزیابی کارایی و سلامت نظام بانکی تبدیل شده‌اند. بانک‌ها و نهادهای نظارتی به‌منظور کنترل این ریسک، همواره به دنبال ابزارها و مدل‌هایی برای پیش‌بینی احتمال نکول مشتریان و تحلیل عوامل مؤثر بر بازپرداخت یا عدم بازپرداخت تسهیلات بوده‌اند. در پاسخ به این کاستی‌ها، در سال‌های اخیر هوش مصنوعی<sup>۲</sup> و به‌ویژه یادگیری ماشین<sup>۳</sup> به‌عنوان ابزارهای نوین تحلیل داده، مورد توجه پژوهشگران و فعالان حوزه مالی قرار گرفته‌اند. الگوریتم‌هایی مانند شبکه‌های عصبی مصنوعی، درخت‌های تصمیم، جنگل تصادفی، ماشین‌های بردار پشتیبان، و مدل‌های یادگیری عمیق، توانسته‌اند با یادگیری از حجم عظیم داده‌های تاریخی، روابط

<sup>1</sup> Non-Performing Loans – NPLs

<sup>2</sup> Artificial Intelligence

<sup>3</sup> Machine Learning

پیچیده میان ویژگی‌های مشتری و احتمال بازپرداخت را شناسایی کرده و مدل‌هایی با دقت بالا ارائه دهند (Lessmann et al., 2015 و Zhang et al., 2021).

در این میان، هوش مصنوعی توضیح‌پذیر<sup>۱</sup> به‌عنوان راهکاری نوین در علم داده پدید آمده است که هدف آن، افزایش شفافیت، درک‌پذیری و اعتمادپذیری مدل‌های پیچیده یادگیری ماشین است. XAI مجموعه‌ای از روش‌ها و الگوریتم‌هایی را شامل می‌شود که قادرند علل و منطق تصمیمات مدل‌های هوش مصنوعی را برای انسان قابل تفسیر سازند. روش‌هایی مانند LIME، SHAP، Anchors و تصمیمات مبتنی بر ویژگی<sup>۲</sup> از جمله تکنیک‌های کلیدی در این حوزه هستند که کاربردهای مهمی در بانکداری و تحلیل ریسک اعتباری پیدا کرده‌اند (Barredo Arrieta et al., 2020 و Ribeiro et al., 2016).

علل شکل‌گیری مطالبات غیرجاری یکی از مهم‌ترین مباحث در تحلیل سلامت نظام بانکی و پایداری مالی است. این پدیده از تعامل عوامل متعددی در سطوح کلان اقتصادی، ساختاری و نهادی، بانک‌محور، و رفتاری ناشی می‌شود که در ادامه به‌طور جامع، دقیق و مستند بررسی می‌شود. در سطح کلان اقتصادی، عوامل مرتبط با چرخه‌های تجاری و نوسانات اقتصادی نقش اصلی را ایفا می‌کنند. رکود اقتصادی، کاهش رشد تولید ناخالص داخلی (GDP)، کاهش درآمدهای ملی، و افزایش نرخ بیکاری از مهم‌ترین متغیرهایی هستند که به کاهش توان بازپرداخت تسهیلات توسط خانوارها و بنگاه‌ها منجر می‌شوند. در چنین شرایطی، فروش و سود شرکت‌ها کاهش می‌یابد و مشتریان حقیقی نیز با مشکلات درآمدی مواجه می‌شوند که به ناتوانی در بازپرداخت وام‌ها منجر می‌گردد. افزایش نرخ بهره نیز باعث می‌شود هزینه بازپرداخت تسهیلات بالا رفته و فشار مضاعفی بر بدهکاران وارد شود، به‌ویژه در وام‌هایی با نرخ بهره شناور. نوسانات نرخ ارز نیز به‌ویژه در کشورهای در حال توسعه، بر شرکت‌های واردکننده یا دارای بدهی ارزی تأثیر منفی گذاشته و قدرت پرداخت آن‌ها را کاهش می‌دهد (Bofondi & Ropele, 2011).

در سطح بانک و نظام اعتباری، ضعف در سیستم‌های ارزیابی و رتبه‌بندی اعتباری، نبود مدل‌های پیشرفته سنجش ریسک، و اتکای زیاد به ضمانت‌های سنتی از دلایل اصلی افزایش مطالبات غیرجاری هستند. بسیاری از بانک‌ها، به‌ویژه در کشورهایی با نظام مالی توسعه نیافته، تسهیلات را بدون بررسی دقیق سابقه مالی، ظرفیت بازپرداخت، و وضعیت درآمدی مشتری اعطا می‌کنند. این وضعیت در صورتی وخیم‌تر می‌شود که اعطای وام تحت تأثیر فشارهای سیاسی، ملاحظات شخصی، یا فساد نهادی صورت گیرد. همچنین، فقدان سیستم نظارتی مؤثر بر نحوه مصرف تسهیلات، باعث می‌شود منابع تخصیص‌یافته در مسیرهای غیرمولد یا پرریسک مصرف شود و احتمال نکول افزایش یابد (Messai & Jouini, 2013).

از سوی دیگر، ناکارآمدی‌های ساختاری در نظام حقوقی و قضایی نیز نقش مهمی دارند. طولانی بودن روند دادرسی، ناتوانی در اجرای وثایق، نبود دادگاه‌های تخصصی مالی، و هزینه‌های بالای پیگیری قضایی موجب می‌شود بانک‌ها در

<sup>1</sup> Explainable Artificial Intelligence - XAI

<sup>2</sup> Feature Attribution

وصول مطالبات با موانع زیادی مواجه باشند. این امر منجر به شکل‌گیری یک فضای «ریسک اخلاقی» می‌شود؛ یعنی وام‌گیرندگان بدحساب انگیزه‌ای برای بازپرداخت ندارند، زیرا اطمینان دارند بانک ابزار مؤثری برای اعمال فشار قانونی بر آن‌ها ندارد (Louzis et al., 2012). رایج‌ترین شاخص، نسبت مطالبات غیرجاری به کل تسهیلات اعطایی<sup>۱</sup> است که به‌صورت درصدی از کل تسهیلات اعطا شده توسط بانک که در طبقه‌بندی معوق یا مشکوک‌الوصول قرار گرفته‌اند، تعریف می‌شود. این شاخص بیانگر سهم تسهیلات معیوب در پرتفوی بانک است و هرچه این نسبت بالاتر باشد، نشانه‌ای از ضعف مدیریت ریسک اعتباری و کاهش کیفیت دارایی‌های بانک محسوب می‌شود. مطابق دستورالعمل کمیته بال، تسهیلاتی که بیش از ۹۰ روز پرداخت نشده باشند یا بازپرداخت آن‌ها نامطمئن تلقی شود، در طبقه NPL قرار می‌گیرند (Basel Committee on Banking Supervision, 2017).

شاخص دیگر، نسبت مطالبات غیرجاری به سرمایه بانک<sup>۲</sup> است که نشان می‌دهد حجم NPLها تا چه حد سرمایه بانک را تهدید می‌کند. اگر این نسبت زیاد باشد، بدین معناست که بانک در صورت عدم وصول این مطالبات، دچار کسری سرمایه خواهد شد. این شاخص از منظر نظارتی برای ارزیابی کفایت سرمایه بانک‌ها در برابر ریسک‌های اعتباری بسیار حائز اهمیت است، زیرا سرمایه باید به‌عنوان سپر ضربه‌گیر در برابر زیان‌های بالقوه عمل کند. نسبت مطالبات غیرجاری به دارایی‌ها<sup>۳</sup> شاخصی است که نشان می‌دهد مطالبات غیرجاری چه سهمی از کل دارایی‌های بانک را تشکیل می‌دهند. این شاخص نیز بر توان نقد شوندگی و انعطاف‌پذیری بانک در مدیریت ترازنامه اثرگذار است، زیرا بخش غیرقابل بازیافت دارایی‌ها، بار مالی و اداری زیادی برای بانک ایجاد می‌کند. نسبت پوشش مطالبات غیرجاری<sup>۴</sup> که از تقسیم ذخایر مطالبات مشکوک‌الوصول<sup>۵</sup> بر کل NPLها به دست می‌آید، نشان می‌دهد که بانک تا چه میزان در برابر ریسک عدم وصول مطالبات آماده است. این شاخص یکی از مهم‌ترین معیارهای ارزیابی سلامت مالی بانک‌ها در زمان مواجهه با بحران است. نسبت پایین نشان‌دهنده آن است که بانک ذخیره کافی برای پوشش زیان‌های اعتباری ندارد و در نتیجه ممکن است در صورت افزایش نکول، با کاهش سرمایه مواجه شود.

علاوه بر این، نسبت تسهیلات معوق به درآمد بهره‌ای<sup>۶</sup> نیز در برخی پژوهش‌ها به‌کار می‌رود تا نشان دهد چه مقدار از منابع درآمدی بانک در معرض ریسک عدم تحقق قرار دارد. این شاخص به‌ویژه در تحلیل پایداری درآمدزایی بانک‌ها در شرایط نوسانی بازار اهمیت می‌یابد.

<sup>1</sup> NPL Ratio

<sup>2</sup> NPL to Capital

<sup>3</sup> NPL to Total Assets

<sup>4</sup> Coverage Ratio

<sup>5</sup> Loan Loss Provisions

<sup>6</sup> NPL to Interest Income

در سال‌های اخیر و با توسعه فناوری‌های تحلیلی، شاخص‌های پیش‌بینی‌کننده کیفیت پرتفوی اعتباری نیز مورد توجه قرار گرفته‌اند؛ مانند نسبت وام‌های با رتبه اعتباری ضعیف به کل پرتفوی، شاخص انباشت تأخیر<sup>۱</sup>، و میزان بازبایی مطالبات معوق<sup>۲</sup> این شاخص‌ها در ترکیب با مدل‌های یادگیری ماشین و تحلیل کلان‌داده، در فرآیند رتبه‌بندی ریسک اعتباری و هشدار زودهنگام نقش پررنگی یافته‌اند (BIS, 2020).

بنابراین، ارزیابی دقیق و مستمر مطالبات غیرجاری از طریق این شاخص‌ها، نه تنها برای حفظ سلامت نظام بانکی، بلکه برای ثبات اقتصادی در سطح کلان ضروری است. ناظران مالی و بانک‌های مرکزی معمولاً بر این شاخص‌ها به‌عنوان معیارهای اصلی ارزیابی ریسک بانکی در گزارش‌های ادواری خود تأکید می‌ورزند.

پیش‌بینی در داده‌های مالی یکی از پیچیده‌ترین و چالش‌برانگیزترین حوزه‌ها در علم داده و تحلیل آماری است. پیچیدگی ساختاری، پویایی محیط اقتصادی، وابستگی‌های غیرخطی، و تأثیر شدید رویدادهای غیرمنتظره باعث می‌شود که مدل‌سازی و پیش‌بینی متغیرهای مالی با دشواری‌های قابل توجهی مواجه شود. این چالش‌ها، هم در سطح نظری و مفهومی، و هم در سطح عملی و محاسباتی ظاهر می‌شوند. در ادامه، مهم‌ترین چالش‌های موجود در این زمینه با تکیه بر ادبیات علمی توضیح داده می‌شود.

یکی از چالش‌های اساسی، ناپایداری داده‌های مالی است. داده‌های مالی نظیر قیمت سهام، نرخ ارز، یا مطالبات بانکی معمولاً دارای روند، نوسانات متغیر، و تغییر در واریانس یا میانگین در طول زمان هستند. بسیاری از مدل‌های آماری کلاسیک (مانند ARIMA یا رگرسیون خطی) نیازمند ایستایی داده‌ها هستند و در مواجهه با سری‌های زمانی ناپایدار، کارایی خود را از دست می‌دهند. این موضوع باعث می‌شود که پیش‌پردازش‌هایی نظیر تفاضل‌گیری یا تبدیل لگاریتمی برای ایستاسازی داده‌ها الزامی باشد (Tsay, 2010).

چالش دوم، نوسان‌پذیری خوشه‌ای<sup>۳</sup> است. بازده دارایی‌ها و نرخ نکول اغلب در بازه‌هایی از زمان رفتار آرام و در بازه‌هایی دیگر نوسانات شدید دارند. این پدیده منجر به آن می‌شود که توزیع داده‌ها از نرمال خارج شده و دارای چولگی یا کشیدگی باشند. چنین ویژگی‌هایی باعث می‌شود که مدل‌هایی مانند رگرسیون خطی یا ARIMA عملکرد ضعیفی داشته باشند و نیاز به استفاده از مدل‌های پیچیده‌تر مانند GARCH یا یادگیری ماشین احساس شود (Cont, 2001). چالش مهم دیگر، وجود روابط غیرخطی و پیچیده میان متغیرها است. در بازارهای مالی، تأثیر یک متغیر بر متغیر دیگر ممکن است در شرایط مختلف به‌گونه‌ای متفاوت ظاهر شود و وابستگی‌ها اغلب غیرخطی هستند. برای مثال، رابطه میان نرخ بهره و مطالبات غیرجاری در شرایط رکود و رونق اقتصادی متفاوت است. مدل‌های کلاسیک که فرض خطی بودن رابطه را دارند، قادر به شناسایی این رفتار نیستند، مگر آن‌که با روش‌های غیرخطی یا مدل‌های یادگیری ماشین ترکیب شوند (Tsay, 2010; Zhang et al., 2020).

<sup>1</sup> Days Past Due

<sup>2</sup> Recovery Rate

<sup>3</sup> Volatility Clustering

یکی دیگر از چالش‌های عمده، وابستگی به شوک‌های بیرونی و داده‌های نویزی است. داده‌های مالی به شدت تحت تأثیر وقایع ناگهانی مانند بحران‌های سیاسی، اخبار اقتصادی، یا تغییرات قوانین قرار می‌گیرند. این عوامل باعث می‌شوند مدل‌ها نتوانند به درستی رفتار آینده را پیش‌بینی کنند، به‌ویژه اگر آموزش مدل تنها بر داده‌های گذشته و بدون در نظر گرفتن متغیرهای بنیادی انجام شده باشد. همچنین، داده‌های مالی دارای نویز بالا هستند که تشخیص الگوهای واقعی را دشوار می‌کند (Taleb, 2007).

چالش دیگر، کمبود داده‌های برجسب‌خورده یا قابل اعتماد است. به‌ویژه در مسائل نظیر پیش‌بینی نکول یا مطالبات غیرجاری، داده‌ها ممکن است ناقص، نامتوازن یا محرمانه باشند. این امر باعث می‌شود مدل‌ها به سمت بیش‌برازش یا خطاهای طبقه‌بندی متمایل شوند. در مدل‌های یادگیری ماشین، استفاده از روش‌هایی مانند oversampling، undersampling یا الگوریتم‌های مقاوم به عدم تعادل، گاهی ضروری می‌شود (Brownlee, 2020).

از سوی دیگر، تغییر در ساختار داده‌ها یا پدیده تغییر رژیم<sup>۱</sup> یکی از چالش‌های مهم در پیش‌بینی بلندمدت در مالی است. برای مثال، تغییر سیاست پولی یا ورود فناوری جدید می‌تواند منجر به تغییر رفتار بازار شود که در داده‌های تاریخی قابل مشاهده نیست. این امر مدل‌ها را دچار ضعف در تعمیم‌دهی می‌کند و نیازمند روش‌هایی نظیر شناسایی تغییر رژیم یا مدل‌های تطبیقی است (Hamilton, 1989).

همچنین، مشکل شفافیت و تفسیرپذیری مدل‌ها به‌ویژه در مدل‌های یادگیری ماشین مانند شبکه‌های عصبی یا جنگل تصادفی، چالشی مهم در حوزه مالی محسوب می‌شود، چراکه تصمیم‌گیرندگان در بانک‌ها و مؤسسات مالی نیازمند درک واضحی از منطق پیش‌بینی هستند. عدم توضیح‌پذیری می‌تواند موجب عدم اعتماد به مدل و عدم پذیرش آن در سیاست‌گذاری شود. در این زمینه، رویکردهایی مانند SHAP یا LIME به‌عنوان ابزارهایی برای تبیین خروجی مدل‌های پیچیده مطرح شده‌اند (Doshi-Velez & Kim, 2017).

در نهایت، مسئله انتخاب ویژگی و پیش‌پردازش داده‌ها در داده‌های مالی اهمیت فوق‌العاده‌ای دارد. وجود ویژگی‌های بیش از حد یا نامرتب می‌تواند باعث پیچیدگی مدل، کاهش دقت، و افزایش زمان محاسبه شود. روش‌های کاهش ابعاد مانند PCA یا انتخاب ویژگی بر پایه اهمیت آماری یا اطلاعاتی، اغلب به کار گرفته می‌شوند تا مدل‌ها بهینه و تفسیرپذیرتر باشند.

کاربرد هوش مصنوعی در پیش‌بینی مطالبات، به‌ویژه مطالبات غیرجاری بانکی، در سال‌های اخیر به یکی از موضوعات مهم در حوزه مالی و بانکی تبدیل شده است. استفاده از الگوریتم‌های یادگیری ماشین، یادگیری عمیق و روش‌های داده‌کاوی، به دلیل توانایی آن‌ها در مدل‌سازی روابط پیچیده، تحلیل حجم بالای داده‌ها، شناسایی الگوهای پنهان و پیش‌بینی رفتار آینده مشتریان، جایگزین روش‌های سنتی آماری شده‌اند. این رویکردها به بانک‌ها و مؤسسات مالی

<sup>۱</sup> Regime Shift

کمک می‌کنند تا ریسک نکول را بهتر مدیریت کرده، سیاست‌های اعتباری را بهینه کنند و تصمیمات مؤثرتری در تخصیص منابع اتخاذ نمایند.

یکی از کاربردهای کلیدی هوش مصنوعی در این زمینه، استفاده از الگوریتم‌های طبقه‌بندی برای پیش‌بینی احتمال نکول یا عدم پرداخت وام است. مدل‌هایی مانند درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان و شبکه‌های عصبی مصنوعی توانسته‌اند با دقت بالایی، مشتریان پرریسک را از مشتریان خوش‌حساب تفکیک کنند. این مدل‌ها با تحلیل داده‌های تاریخی مربوط به سوابق پرداخت، ویژگی‌های جمعیت‌شناختی، رفتار مالی، نوع وام، مدت زمان بازپرداخت، و سایر فاکتورها، قادر به پیش‌بینی وضعیت آینده اقساط وام هستند (Lessmann et al., 2015).

یکی دیگر از مزایا، پردازش سریع و خودکارسازی تصمیم‌گیری‌ها است. الگوریتم‌های هوش مصنوعی می‌توانند هزاران پرونده اعتباری را در زمان کوتاهی بررسی کرده و به سیستم‌های اعطای وام پیشنهاداتی دقیق ارائه دهند، که این امر بهره‌وری بانک را به شدت افزایش می‌دهد. همچنین، قابلیت تطبیق با تغییرات محیطی و یادگیری پیوسته از داده‌های جدید از دیگر نقاط قوت AI محسوب می‌شود، زیرا مدل‌ها با به‌روزرسانی اطلاعات، عملکرد خود را بهبود می‌دهند (Zhang et al., 2020). افزون بر آن، شخصی‌سازی تصمیمات اعتباری برای هر مشتری از طریق تحلیل رفتار فردی و تاریخچه مالی امکان‌پذیر شده و به بانک‌ها این اجازه را می‌دهد که شرایط و نرخ‌های اعتباری مناسب‌تری برای هر مشتری تعیین کنند، که در نهایت منجر به بهبود تجربه مشتری و کاهش ریسک می‌شود (Khandani et al., 2010).

در مقابل، معایب و چالش‌هایی نیز در به‌کارگیری هوش مصنوعی در ارزیابی ریسک اعتباری وجود دارد. نخستین چالش مهم، عدم شفافیت مدل‌ها و دشواری در تفسیر تصمیمات آن‌ها است، به‌ویژه در الگوریتم‌های یادگیری عمیق مانند شبکه‌های عصبی که به‌عنوان «جعبه سیاه» شناخته می‌شوند. این عدم شفافیت می‌تواند اعتماد مدیران و نهادهای نظارتی به نتایج مدل را کاهش دهد و پذیرش آن را با مشکل مواجه سازد (Rudin, 2019). از سوی دیگر، ریسک جانبداری و تبعیض نیز مطرح است؛ اگر داده‌های آموزشی مدل دارای سوگیری باشند، مدل نیز آن را بازتولید خواهد کرد و ممکن است تصمیمات ناعادلانه‌ای در قبال گروه‌های خاصی از افراد اتخاذ شود. این موضوع می‌تواند پیامدهای حقوقی و اخلاقی برای بانک‌ها در پی داشته باشد (Barocas et al., 2019). همچنین، نیاز به داده‌های بزرگ و با کیفیت بالا از دیگر محدودیت‌های این فناوری است. در بسیاری از موارد، داده‌های بانکی ناقص، ناسازگار یا محدود به تاریخچه کوتاه هستند و آموزش مؤثر مدل‌های AI را با مشکل مواجه می‌کنند. هزینه‌های پیاده‌سازی، نگهداری و نیروی انسانی متخصص برای توسعه این سیستم‌ها نیز بالا بوده و ممکن است برای بانک‌های کوچک یا کشورهای در حال توسعه چالش‌برانگیز باشد (Brynjolfsson & McAfee, 2017).

پیوند میان مدل‌های پیش‌بینی‌گر و ابزارهای هوش مصنوعی توضیح‌پذیر به‌عنوان یکی از مؤلفه‌های کلیدی در طراحی سیستم‌های قابل اعتماد و قابل استفاده در حوزه‌های حساس مالی، به‌ویژه در پیش‌بینی ریسک اعتباری و مطالبات غیرجاری، مورد توجه گسترده قرار گرفته است. این پیوند به معنای تعامل بین مدل‌هایی با عملکرد بالا (نظیر

XGBoost, Random Forest, Neural Networks (و غیره) و ابزارهایی است که هدف آن‌ها تبیین فرآیند تصمیم‌گیری این مدل‌ها برای کاربران انسانی، کارشناسان، مدیران ریسک و قانون‌گذاران است (Ribeiro et al., 2016). مدل‌های پیش‌بینی‌گر به‌ویژه آن‌هایی که از یادگیری ماشین استفاده می‌کنند، قادرند الگوهای پیچیده را در داده‌های ساختاریافته مالی کشف کنند و به‌طور دقیق نتایجی مانند احتمال نکول یا عدم بازپرداخت وام را پیش‌بینی نمایند. اما این دقت بالا معمولاً با از دست رفتن شفافیت همراه است، چراکه تصمیمات مدل بر اساس روابط غیرخطی و تعاملات چندبعدی میان ویژگی‌ها اتخاذ می‌شود که برای انسان قابل مشاهده نیست (Lipton, 2018). اینجاست که ابزارهای XAI مانند SHAP, LIME, Integrated Gradients و Counterfactual Explanations وارد عمل می‌شوند.

حسن‌زاده و حبیبی (۱۳۸۹)، در مقاله‌ای با عنوان «کالبد شکافی مطالبات معوق» به چگونگی مصرف منابع جذب شده و نحوه بازگشت مجدد آنها پرداخته و مدیریت صحیح را لازم می‌داند، لذا به منظور جلوگیری از افزایش سهم مطالبات معوق در صورت‌های مالی بانک‌ها مواردی چون: تقویت کادر کارشناسی بانکها، نظارت بر مصرف تسهیلات اعطایی و کنترل در خصوص گشایش اعتبارات اسنادی را پیشنهاد می‌دهد.

خسروانجم و همکاران (۱۴۰۰)، در «شناسایی گلوگاه‌ها و شاخص‌های مؤثر جهت وصول مطالبات معوق بانک با استفاده از روش دیمتل فازی (Fuzzy DEMATEL)» مورد مطالعه یکی از بانک‌های بزرگ تجاری» به منظور شناسایی شاخص‌های مؤثر جهت وصول مطالبات معوق و تجزیه و تحلیل آن‌ها از دو پرسشنامه مجزا جهت گردآوری و تحلیل نظرات مدیران و کارشناسان صاحب‌نظر در حوزه اعتباری و وصول مطالبات استفاده کردند. با استفاده از پرسشنامه اول مؤلفه‌ها و شاخص‌های بدست آمده با چند خبره صاحب‌نظر (۱۰ نفر) در زمینه تحقیق مورد نظر به بحث گذاشته شد تا اصلاحاتی اعمال گردد. در پرسشنامه دوم (۷ نفر) با استفاده از رویکرد دیمتل فازی به منظور شناسایی نقاط قوت و ضعف شاخص‌ها، عوامل و شاخص‌های وصول مطالبات که دارای وابستگی درونی و تأثیر متقابل بر روی یکدیگر هستند مورد تجزیه و تحلیل قرار گرفتند. نتایج تحقیق نشان داد که شاخص چگونگی نظام‌مند کردن نظارت بر وصول مطالبات غیرجاری عامل اصلی در موانع وصول مطالبات معوق می‌باشد و مجموع تأثیرگذاری و تأثیرپذیری این شاخص از دیگر شاخص‌ها بیشتر است. به عبارت دیگر معیار هسته‌ای است و برای شناسایی عوامل اصلی موانع وصول مطالبات باید در اولویت قرار بگیرد.

کارابولوت<sup>۱</sup> و همکاران (۲۰۰۷) در پژوهشی که در کشور ترکیه انجام شده است اثر بیمه سپرده‌ها به صورت نامحدود را بر وام‌های معوق مورد بررسی قرار داده‌اند. در سال ۱۹۹۴ به دلیل بحران مالی دولت ترکیه به اجرای برنامه بیمه سپرده‌ها با نرخ ثابت پرداخت که نتیجه آن بحران مالی بود پس از آن برای خروج از بحران و کاهش مطالبات معوق فزاینده در آن زمان به اجرای بیمه سپرده‌ها به طور نامحدود اقدام کرد که موجب افزایش قابل توجهی در وام‌های معوق گردید. دلیل این امر نیز این بود که بانک‌ها پس از بیمه شدن سپرده‌های بانکی بیشتر به استقبال ریسک می‌رفتند و

<sup>۱</sup> Karabulut

خطر اخلاقی و عدم توجه کافی به ریسک اعتباری متقاضیان وام‌ها، موجب افزایش بیش از پیش مطالبات معوق گردید. نویسندگان در پژوهش فوق از آزمون چاو استفاده کرده و از این طریق نتیجه گرفته است که در سال ۱۹۹۴ تغییرات ساختاری شدیدی در وام‌های معوق پدید آمده است. وی با استفاده از تخمین OLS نشان داد که بیمه سپرده نامحدود در ترکیه، موجب پیدایش وام‌های معوق از طریق وارد کردن خسارت بر کارایی تخصیص سپرده‌ها شده است. ردی<sup>۱</sup> (۲۰۰۲) در پژوهش خود تلاش کرده است دلایل عمده بروز مطالبات NPL و راهکارهای اتخاذ شده در این حوزه را در پنج کشور آسیایی شامل هند، چین، تایلند، کره و ژاپن مورد بررسی قرار دهد. در جمع‌بندی مبانی نظری، مشخص شد که مطالبات غیرجاری نه تنها بازتابی از ناکارآمدی سیستم‌های اعتباری و نظارتی هستند، بلکه ریشه در عوامل کلان اقتصادی، ضعف‌های نهادی، و ناکارآمدی سیستم‌های رتبه‌بندی دارند. بررسی ادبیات نشان داد که ابزارهای هوش مصنوعی، با توان پردازش داده‌های حجیم و کشف روابط پیچیده، نسبت به روش‌های سنتی پیش‌بینی، مزایای قابل توجهی دارند، اما چالش‌هایی نظیر عدم شفافیت، سوگیری داده‌ها، و نیاز به داده‌های با کیفیت همچنان باقی است.

تحقیقات پیشین گرچه استفاده از مدل‌های یادگیری ماشین در پیش‌بینی مطالبات غیرجاری را مؤثر دانسته‌اند، اما کمتر به موضوع «توضیح‌پذیری مدل‌ها» پرداخته‌اند. در این میان، ابزارهایی مانند SHAP و LIME با تبیین منطق پیش‌بینی مدل‌ها، امکان تحلیل دقیق رفتار متغیرها را فراهم کرده‌اند. بنابراین، پژوهش حاضر با رویکردی تلفیقی از مدل‌های پیشرفته و ابزارهای تحلیل‌پذیر، تلاش می‌کند توازن میان دقت و تفسیرپذیری برقرار سازد تا تصمیم‌گیرندگان بتوانند درک عمیق‌تری از پیش‌بینی‌ها و عوامل تأثیرگذار بر آن‌ها داشته باشند.

## روش پژوهش

پژوهش حاضر از نظر هدف، کاربردی و از نظر رویکرد، تحلیلی-کمی است و با بهره‌گیری از الگوریتم‌های یادگیری ماشین و روش‌های هوش مصنوعی توضیح‌پذیر، به دنبال طراحی مدلی برای پیش‌بینی احتمال وصول مطالبات غیرجاری در قراردادهای با بدهی سررسیدشده بین ۳۰ تا ۹۰ روز است. این تحقیق در زمره پژوهش‌های داده‌محور<sup>۲</sup> قرار می‌گیرد که با استفاده از داده‌های واقعی بانکی و اعتباری، تلاش می‌کند الگویی دقیق و قابل تفسیر برای تصمیم‌گیری اعتباری ارائه دهد. با توجه به ویژگی‌های خاص داده‌های مالی و پیچیدگی رفتار مشتریان، پژوهش از رویکرد مدل‌سازی پیش‌بینی‌کننده بهره می‌گیرد تا بتواند از طریق تحلیل الگوهای موجود در داده‌ها، روابط مؤثر بر احتمال نکول و بازپرداخت را استخراج و تبیین کند.

با توجه به اهمیت مسئله وصول مطالبات در فرایندهای بانکی، همواره برخورد مناسب و اصولی با مشتریان بدحساب جهت بهبود وضعیت آن‌ها نیاز به پیش‌بینی و شناسایی این افراد با دقت بالا و در زمان مناسب دارد. بنابراین جهت

<sup>۱</sup> Reddy

<sup>۲</sup> Data-Driven

کاهش هزینه عملیاتی و انسانی در شناسایی این افراد و همچنین کاهش حداکثری نارضایتی مشتریان عموماً خوش حساب و با رفتار بازپرداختی نامناسب مقطعی، نیاز به یک مدل هوشمند با دقت بالا احساس می‌شود. با پیشرفت الگوریتم‌های هوش مصنوعی و یادگیری ماشین، بهبود قابل توجهی در عملکرد بسیاری از حوزه‌های مختلف کسب و کاری که از هوش مصنوعی مبتنی بر داده‌ها استفاده می‌کنند، حاصل شده است. بنابراین، می‌توان گفت که استفاده از الگوریتم‌های مبتنی بر یادگیری ماشین داده محور در کنار دقت و سرعت بالا در اجرا، می‌تواند از سوگیری‌های اشتباه در اتخاذ تصمیمات جلوگیری کند. از این رو در پژوهش پیش رو، جهت شناسایی افراد بدحساب با احتمالاً بالای وخیم‌تر شدن وضعیت بازپرداختی آن‌ها، از الگوریتم‌های مبتنی بر یادگیری ماشین استفاده می‌شود.

جهت پیش‌بینی و شناسایی افراد بدحساب با توجه به هدف وصول مطالبات، می‌بایست متغیر وابسته، به گونه‌ای تعریف شود که یک هدف کسب و کاری خاص را برآورده سازد. در این پژوهش احتمال نکول به عنوان متغیر وابسته اتخاذ شده است. نکول در این تحقیق اینگونه تعریف شده است احتمال این که حسابی که بیش از ۳۰ روز و کمتر از ۹۰ روز بدهی سررسید شده پرداخت نشده داشته باشد.

عملیات تفکیک داده (تقسیم داده<sup>۱</sup>) اغلب در یادگیری ماشین برای جداسازی داده‌ها به سه مجموعه آموزشی<sup>۲</sup>، آزمایشی<sup>۳</sup> و مجموعه اعتبار مدل<sup>۴</sup> مورد استفاده قرار می‌گیرد. جداسازی و تفکیک داده‌ها (تقسیم داده‌ها) به داده‌های آموزشی و داده‌های آزمایشی<sup>۵</sup> روشی برای سنجش کیفیت عملکرد یک الگوریتم یادگیری ماشین به حساب می‌آید. از تفکیک داده می‌توان برای مسائل دسته‌بندی<sup>۶</sup> یا رگرسیون استفاده کرد و به طور کلی این رویکرد در هر نوع الگوریتم یادگیری نظارت شده‌ای کاربرد دارد.

جامعه آماری این پژوهش شامل کلیه اشخاص حقیقی دارای سابقه فعالیت بانکی و اطلاعات اعتباری ثبت‌شده در پایگاه داده شرکت مشاوره رتبه‌بندی اعتباری ایران است. این شرکت، که در سال ۱۳۸۵ با نظارت بانک مرکزی جمهوری اسلامی ایران و حمایت وزارت امور اقتصادی و دارایی و مشارکت بانک‌ها و نهادهای مالی کشور تأسیس شد، به‌عنوان مرجع ملی اعتبارسنجی در کشور فعالیت می‌کند. داده‌های گردآوری‌شده در این شرکت از طریق اتصال مستقیم با سامانه‌های اطلاعاتی بانک‌ها، مؤسسات اعتباری، شرکت‌های لیزینگ، شهرداری‌ها و سایر تأمین‌کنندگان اطلاعات مالی صورت می‌پذیرد. بنابراین، پایگاه داده این شرکت دربرگیرنده گستره وسیعی از اطلاعات مالی، اعتباری، جمعیت‌شناختی، الگوهای پرداخت، وضعیت نکول، تاریخچه تسهیلات دریافتی و سایر شاخص‌های رفتاری مشتریان حقیقی در مقیاس ملی است.

<sup>1</sup> Data Splitting

<sup>2</sup> Training Set

<sup>3</sup> Test Set

<sup>4</sup> Validation Set

<sup>5</sup> Train-Test Split

<sup>6</sup> Classification

در انتخاب نمونه آماری از روش نمونه‌گیری تصادفی ساده استفاده شده است. این روش، یکی از پایه‌ای‌ترین و علمی‌ترین روش‌های نمونه‌گیری آماری محسوب می‌شود که در آن هر عضو جامعه آماری دارای احتمال مساوی برای انتخاب شدن است. دلیل استفاده از این روش در پژوهش حاضر، اجتناب از هرگونه سوگیری در انتخاب داده‌ها، افزایش اعتبار نتایج، و فراهم‌سازی زمینه‌ای برای تعمیم‌پذیری مدل به کل جامعه هدف بوده است.

در این پژوهش، برای دستیابی به نتایج قابل تعمیم و مدل‌سازی دقیق، تعداد ۷۵۰۰۰۰ رکورد مربوط به اشخاص حقیقی به‌عنوان نمونه آماری مورد استفاده قرار گرفته است. انتخاب این حجم از نمونه، به‌صورت هدفمند و با در نظر گرفتن پیچیدگی‌های الگوریتم‌های یادگیری ماشین انجام شده است. مدل‌های پیشرفته مانند جنگل تصادفی، گرادیان تقویتی، یا شبکه‌های عصبی عمیق، برای رسیدن به دقت بالا و جلوگیری از بیش‌برازش<sup>۱</sup>، به حجم بالایی از داده‌های آموزش و آزمایش نیاز دارند. بنابراین، استفاده از داده‌های وسیع و متنوع، نه‌تنها منجر به بهبود عملکرد مدل‌ها می‌شود، بلکه باعث می‌شود نتایج حاصل به شرایط واقعی نظام بانکی نزدیک‌تر باشند.

در این پژوهش، با هدف پیش‌بینی ریسک وصول مطالبات با حداکثر دقت ممکن، از ترکیبی از الگوریتم‌های پیشرفته یادگیری عمیق و روش‌های هوش مصنوعی توضیح‌پذیر بهره گرفته شده است. رویکرد اصلی پژوهش مبتنی بر تحلیل داده‌محور، طراحی مدل پیش‌بینی و تفسیر دقیق خروجی‌های مدل است تا علاوه بر دقت بالا در پیش‌بینی، امکان تبیین و توضیح نتایج برای کاربران نهایی (مانند بانک‌ها و مؤسسات اعتباری) نیز فراهم گردد.

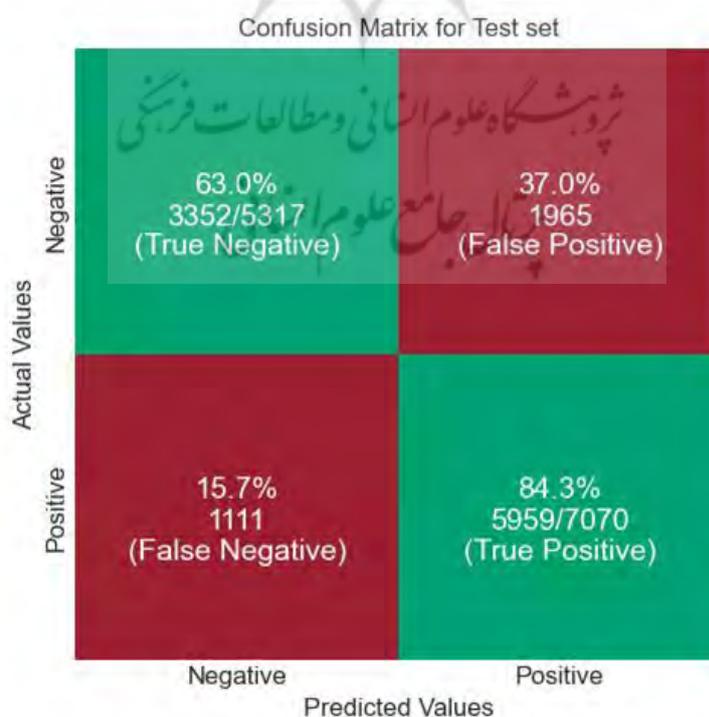
در این تحقیق با هدف ارائه مدلی برای پیش‌بینی وصول مطالبات غیرجاری با بهره‌گیری از رویکردهای نوین هوش مصنوعی توضیح‌پذیر، ابتدا نوع پژوهش به صورت کاربردی و توسعه‌ای معرفی شد. جامعه آماری شامل داده‌های مربوط به مشتریان دارای مطالبات غیرجاری در یک بازه زمانی مشخص بوده و روش نمونه‌گیری به صورت هدفمند و مبتنی بر معیارهای مشخص صورت گرفت. داده‌ها از منابع اطلاعاتی بانکی معتبر استخراج شده و پس از پیش‌پردازش شامل پاک‌سازی، نرمال‌سازی و مهندسی ویژگی، به مدل‌های منتخب یادگیری ماشین (نظیر XGBoost، Random Forest و شبکه‌های عصبی) وارد شدند. در ادامه، برای ارتقای قابلیت تفسیر مدل و شفاف‌سازی نتایج، از تکنیک‌های هوش مصنوعی توضیح‌پذیر مانند SHAP و LIME استفاده شد. در نهایت، با به‌کارگیری شاخص‌های ارزیابی مناسب همچون دقت، یادآوری و AUC، عملکرد مدل‌ها سنجیده شد تا مدلی بهینه، دقیق و قابل تفسیر برای پیش‌بینی احتمال وصول مطالبات غیرجاری ارائه شود.

### یافته‌های پژوهش

در این پژوهش، برای ارزیابی عملکرد مدل پیش‌بینی وصول مطالبات غیرجاری، از ماتریس درهم‌ریختگی استفاده شد که یکی از ابزارهای کلیدی در تحلیل مدل‌های طبقه‌بندی است. در این تحلیل، مشتریان در دو دسته «خوش‌حساب» و «بدحساب» طبقه‌بندی شده‌اند و هدف اصلی مدل، شناسایی دقیق مشتریانی است که در سه ماه

<sup>۱</sup> Overfitting

آینده احتمال عدم بازپرداخت بدهی توسط آن‌ها وجود دارد. نتایج به دست آمده از ماتریس درهم‌ریختگی نشان داد که مدل توانسته است ۸۴/۳ درصد از مشتریان بدحساب را به درستی شناسایی کند (True Positive)، که این امر بیانگر دقت بالای مدل در شناسایی افراد پرریسک است و برای بانک‌ها در فرایند تصمیم‌گیری اعتباری بسیار حیاتی محسوب می‌شود. در سوی دیگر، ۶۳ درصد از مشتریان خوش حساب نیز به درستی توسط مدل شناسایی شده‌اند (True Negative) که نشان‌دهنده عملکرد قابل قبول مدل در تشخیص افراد متعهد به پرداخت است. با این حال، میزان False Positive در حدود ۳۷ درصد نشان‌دهنده آن است که تعدادی از مشتریان خوش حساب به اشتباه در دسته بدهکاران قرار گرفته‌اند؛ این موضوع ممکن است منجر به تصمیمات ناعادلانه اعتباری مانند رد درخواست وام یا افزایش نرخ بهره شود و پیامدهایی در رضایت مشتری و سیاست‌های بانکی به دنبال داشته باشد. همچنین، میزان False Negative در حدود ۱۵/۷ درصد به این معناست که برخی از بدهکاران به اشتباه به عنوان افراد خوش حساب شناسایی شده‌اند که این موضوع می‌تواند باعث افزایش خطرات اعتباری برای بانک گردد. این نتایج نشان می‌دهد که اگرچه دقت کلی مدل نسبتاً مطلوب است، اما برای بهینه‌سازی عملکرد نهایی، نیاز به بررسی دقیق‌تر آستانه تصمیم‌گیری و به کارگیری تکنیک‌های تنظیم مدل وجود دارد. مقدار آستانه‌ای که برای طبقه‌بندی انتخاب شده، بر اساس تحلیل منحنی AUC تعیین شده و نقش مهمی در تعادل میان نرخ‌های خطای مدل ایفا می‌کند. تحقیقات پیشین نیز تأکید کرده‌اند که انتخاب بهینه آستانه و استفاده از مدل‌های قابل توضیح در تصمیم‌گیری‌های مالی می‌تواند اثربخشی و عدالت سیستم‌های اعتبارسنجی را افزایش دهد (Ribeiro et al., 2016; Lundberg & Lee, 2017).



نمودار ۱. تحلیل ماتریس درهم‌ریختگی (Source: By author)

به‌طور کلی، یافته‌های این تحقیق با مطالعات مشابه مانند پژوهش Athey et al. (2019) و Bertsimas et al. (2020) همسو است که نشان داده‌اند استفاده از مدل‌های یادگیری ماشین همراه با الگوریتم‌های هوش مصنوعی توضیح‌پذیر می‌تواند دقت پیش‌بینی را افزایش داده و در عین حال دلایل تصمیمات مدل را برای استفاده‌کنندگان نهایی شفاف کند. در نهایت، برای ارتقای سیستم پیش‌بینی وصول مطالبات، بهینه‌سازی ساختار مدل، تنظیم دقیق آستانه‌ها، و استفاده از ابزارهای تحلیل توضیح‌پذیر مانند SHAP یا LIME پیشنهاد می‌شود تا ضمن افزایش دقت مدل، اعتماد تصمیم‌گیرندگان به نتایج آن نیز تقویت شود.

تحلیل عملکرد مدل پیش‌بینی وصول مطالبات غیرجاری با استفاده از منحنی ROC و معیار AUC نشان‌دهنده اثربخشی مطلوب الگوریتم در تفکیک دو گروه اصلی مشتریان یعنی افراد متعهد به پرداخت و افراد دارای ریسک عدم پرداخت است. در این تحلیل، مدل به‌گونه‌ای طراحی شده است که توانایی تمایز بین این دو گروه را با دقت قابل قبولی انجام دهد؛ به طوری که مقدار AUC برابر با ۴۸/۸۸ درصد به دست آمده است. این عدد به‌عنوان شاخصی از عملکرد کلی مدل در تمام سطوح آستانه، به‌طور مستقیم بیانگر آن است که در ۴۸/۸۸ درصد مواقع، مدل به‌درستی قادر به تمایز میان یک مشتری بدهکار و یک مشتری خوش حساب است، که مطابق با دسته‌بندی‌های استاندارد، یک مدل با AUC بین ۸۰ تا ۹۰ درصد به‌عنوان مدل «قوی» در نظر گرفته می‌شود (Bradley, 1997).

نمودار ROC به‌عنوان ابزاری برای بررسی تعادل بین نرخ مثبت واقعی (True Positive Rate یا Sensitivity) و نرخ مثبت کاذب (False Positive Rate) در سناریوهای مختلف آستانه، کاربرد بسیار مهمی دارد. همان‌طور که Fawcett (2006) اشاره می‌کند، هرچه منحنی ROC به گوشه بالا سمت چپ نزدیک‌تر باشد، مدل از توان تفکیک‌پذیری بالاتری برخوردار است. در این پژوهش نیز منحنی به‌دست آمده، با فاصله قابل توجهی از خط قطری (AUC = 50%) قرار دارد که نشان‌دهنده عملکرد برتر نسبت به یک مدل تصادفی است.

#### تحلیل نمودار طبقه بندی گزارش Heatmap

در این بخش از پژوهش، تحلیل نمودار با هدف ارزیابی دقیق عملکرد مدل پیش‌بینی وصول مطالبات غیرجاری بر مبنای هوش مصنوعی توضیح‌پذیر انجام شده است. این نمودار، عملکرد مدل را از منظر چهار شاخص کلیدی - Precision، Recall، F1-score و Support - برای هر کلاس به صورت مجزا و نیز در سطح کلی نمایش می‌دهد. چنین تحلیلی به ویژه در زمینه‌هایی نظیر پیش‌بینی رفتار مشتریان بانکی که دارای پیامدهای مالی مهمی هستند، از اهمیت بالایی برخوردار است (Serrano-Cinca et al., 2015). در نتایج به‌دست آمده، مشاهده شد که مدل در طبقه‌بندی نمونه‌های کلاس «bad» (مشتریان با احتمال نکول بالا) عملکرد بهتری دارد (Precision = 0.84، Recall = 0.79، F1-score = 0.79) نسبت به کلاس «good» (مشتریان خوش حساب) که دارای مقادیر پایین‌تری در شاخص‌های یادشده است (Precision = 0.75، Recall = 0.63، F1-score = 0.69). این تفاوت می‌تواند به دلیل حجم بالاتر داده‌های کلاس

«bad» (n = 7070) در مقایسه با کلاس «good» (n = 5317) باشد. چنین نامتوازنی در داده‌ها معمولاً منجر به عملکرد بهتر مدل در طبقه‌ای با نمونه‌های بیشتر می‌شود (He & Garcia, 2009).

Macro Average که میانگین ساده‌ای از عملکرد روی هر کلاس است، و Weighted Average که عملکرد را بر اساس وزن کلاس‌ها (تعداد نمونه‌ها) محاسبه می‌کند، هر دو حدود ۰/۷۵ گزارش شده‌اند. نزدیکی این دو مقدار نشان می‌دهد که علی‌رغم عدم توازن کامل داده‌ها، عملکرد مدل در هر دو کلاس نسبتاً متعادل بوده و مدل دچار سوگیری جدی نسبت به یکی از کلاس‌ها نشده است. این ویژگی از منظر عدالت تصمیم‌گیری در سیستم‌های مالی اهمیت دارد (Barocas et al., 2019). عملکرد کلی مدل با میانگین F1 برابر ۰/۷۵ نشان‌دهنده کارایی قابل قبول الگوریتم در تمایز بین مشتریان خوش حساب و بدحساب است. با این حال، ضعف نسبی در تشخیص صحیح نمونه‌های کلاس good با Recall = 0.63 می‌تواند منجر به افزایش موارد false negative شود، که در کاربردهای عملی به معنای از دست رفتن فرصت‌های اعتباری مطمئن است. لذا پیشنهاد می‌شود برای افزایش کارایی مدل، اقداماتی همچون تنظیم آستانه تصمیم‌گیری، استفاده از روش‌های بازنمونه‌گیری، یا اعمال جریمه (cost-sensitive learning) در دستور کار قرار گیرد.

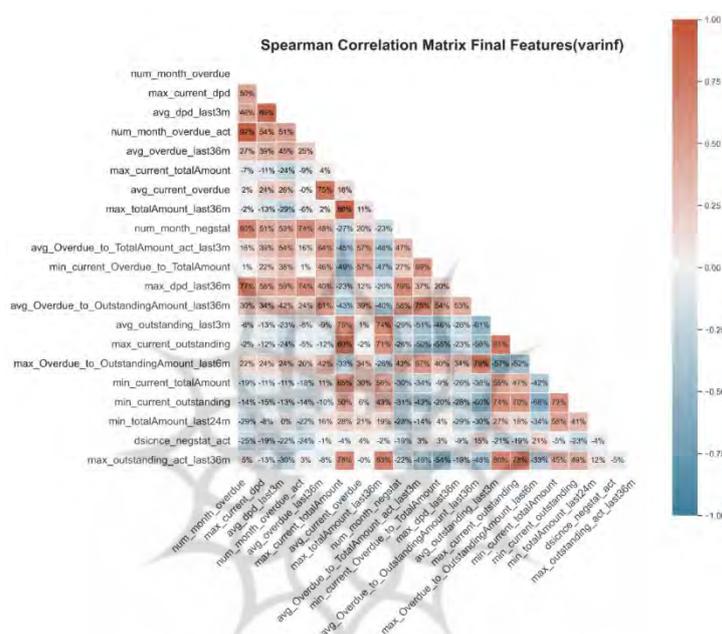
Classification Results for Test set

Classification Report Heatmap				Overall Classification Report Heatmap					
good	0.75	0.63	0.69	5,317	macro avg	0.75	0.74	0.74	12,387
bad	0.75	0.84	0.79	7,070	weighted avg	0.75	0.75	0.75	12,387
	precision	recall	f1-score	support		precision	recall	f1-score	support

نمودار ۲. تحلیل نمودار طبقه بندی گزارش (Source: By author)

در این پژوهش، برای بررسی میزان ارتباط میان متغیرهای مدل، از ماتریس همبستگی اسپیرمن استفاده شد که برخلاف روش پیرسون، قادر به شناسایی روابط غیرخطی و یکنواخت میان متغیرهاست. نتایج حاصل از این ماتریس نشان داد که برخی ویژگی‌ها مانند تعداد ماه‌های تأخیر و بیشترین میزان تأخیر جاری دارای همبستگی مثبت قوی با یکدیگر بودند (ضریب حدود ۰/۸۶) و نیز بین تعداد ماه‌های تأخیر و تعداد ماه‌های تأخیر فعال، همبستگی مثبت بسیار بالا مشاهده شد (ضریب حدود ۰/۹۲). همچنین، برخی متغیرها مانند مدت‌زمان از آخرین وضعیت منفی و بیشینه بدهی سه‌سال گذشته دارای همبستگی منفی قوی بودند (ضریب حدود ۰/۸۳-). در مقابل، بسیاری از متغیرها همبستگی ضعیف داشتند که نشان‌دهنده استقلال بیشتر آن‌ها و مناسب بودن برای ورود به مدل پیش‌بینی است. این یافته‌ها به‌طور کلی با نتایج ماتریس همبستگی پیرسون همخوانی داشت، اما استفاده از همبستگی اسپیرمن به دلیل حساسیت بیشتر نسبت به روابط غیرخطی، دید دقیق‌تری نسبت به ساختار درونی داده‌ها فراهم کرد. همچنین برای افزایش شفافیت و قابلیت تبیین مدل یادگیری ماشین، از ابزار SHAP استفاده شد. تحلیل نمودارهای SHAP نشان داد که برخی ویژگی‌ها مانند تعداد ماه‌های تأخیر، بیشترین میزان بدهی جاری و متوسط تأخیر در سه ماه اخیر بیشترین تأثیر را در پیش‌بینی وصول یا عدم وصول مطالبات داشتند. SHAP این امکان را فراهم کرد که نقش مستقل هر ویژگی در

خروجی مدل به صورت مجزا تحلیل شود و مشخص گردد که هر متغیر در کدام ناحیه از مقادیر خود بیشترین اثر مثبت یا منفی را بر پیش‌بینی دارد. این تحلیل‌ها در کنار غربال‌گری انجام‌شده از طریق شاخص تورم واریانس، به حذف متغیرهای دارای هم‌خطی شدید و انتخاب مجموعه‌ای پایدار و قابل اعتماد از ویژگی‌ها منجر شد. در مجموع، ترکیب تحلیل‌های همبستگی و ابزار تبیین‌پذیری SHAP موجب افزایش دقت و شفافیت مدل شده و امکان استفاده عملی از آن در نظام‌های تصمیم‌یار اعتباری را فراهم می‌کند.



نمودار ۳. ماتریس همبستگی (Source:By author)

نتایج نشان داد که مدل‌های یادگیری ماشین، به‌ویژه درخت تصمیم و جنگل تصادفی، با دقت بالا قادر به شناسایی مشتریان پرریسک و تشخیص قراردادهای خوددرمان‌شونده هستند. ابزار SHAP نیز با تبیین سهم متغیرهای کلیدی مانند تعداد ماه‌های تأخیر و میانگین بدهی معوق، شفافیت قابل توجهی در تحلیل نتایج مدل فراهم کرده است. این یافته‌ها حاکی از آن است که مدل‌های هوشمند می‌توانند با دقت بالا و تفسیرپذیری مناسب، ابزار کارآمدی در مدیریت هوشمند مطالبات بانکی باشند.

### بحث و نتیجه‌گیری

در این تحقیق، مدل پیش‌بینی وصول مطالبات غیرجاری مبتنی بر هوش مصنوعی توضیح‌پذیر ارائه و ارزیابی شد. هدف اصلی از این تحقیق، توسعه مدلی بود که بتواند به‌طور دقیق مطالبات غیرجاری را پیش‌بینی کرده و در عین حال، امکان تفسیر و تحلیل نتایج آن برای تصمیم‌گیرندگان و کارشناسان فراهم شود. پیش‌بینی وصول مطالبات غیرجاری یکی از چالش‌های مهم در حوزه مالی و اعتباری است که تأثیر مستقیم بر مدیریت ریسک و بهبود وضعیت مالی

سازمان‌ها دارد. در این راستا، استفاده از تکنیک‌های هوش مصنوعی به‌ویژه یادگیری ماشین و ابزارهای توضیح‌پذیر نظیر SHAP به‌منظور تحلیل ویژگی‌های مؤثر در پیش‌بینی و تفسیر مدل، اهمیت زیادی دارد.

در این تحقیق، ابتدا داده‌های مربوط به مطالبات غیرجاری جمع‌آوری و ویژگی‌های مختلفی که می‌توانند بر پیش‌بینی تأثیرگذار باشند، شناسایی شدند. سپس با استفاده از الگوریتم‌های مختلف یادگیری ماشین، مدل‌هایی برای پیش‌بینی وصول مطالبات غیرجاری طراحی شد. در ادامه، به تحلیل و ارزیابی عملکرد این مدل‌ها پرداخته شد و نتایج به‌دست‌آمده با استفاده از ابزارهای توضیح‌پذیر مانند SHAP، به‌طور دقیق تفسیر شدند.

مدل‌های یادگیری ماشین برای قراردادهای با بدهی سررسید شده پرداخت نشده بین ۳۰ تا ۹۰ روز، قدرت تفکیک و دقت قابل توجهی برای جداسازی قراردادهای خوددرمان شونده و دیگر قراردادها در ۹۰ روز آینده دارد. در تحقیق حاضر به بررسی توانمندی مدل‌های یادگیری ماشین برای شناسایی و تفکیک قراردادهای با بدهی سررسید شده بین ۳۰ تا ۹۰ روز می‌پردازد که احتمال خوددرمانی در ۹۰ روز آینده را دارند. این فرضیه، موضوعی کلیدی در زمینه پیش‌بینی وصول مطالبات غیرجاری و پیش‌بینی رفتار مشتریان است که می‌تواند تأثیر زیادی در کاهش ریسک‌های مالی و بهینه‌سازی فرآیندهای بازپرداخت بدهی‌ها داشته باشد. به‌ویژه، این فرضیه به دنبال ارزیابی قدرت تفکیک مدل‌های یادگیری ماشین برای شناسایی قراردادهای خوددرمان شونده از دیگر قراردادها در بازه زمانی ۹۰ روزه است. در این راستا، مدل‌های یادگیری ماشین، به‌ویژه مدل‌هایی مانند درخت تصمیم، جنگل تصادفی و ماشین‌های بردار پشتیبان (SVM)، توانسته‌اند نقش مؤثری در شناسایی الگوهای پیچیده در داده‌های مالی ایفا کنند. این مدل‌ها به دلیل توانایی‌شان در شبیه‌سازی روابط غیرخطی و تعاملات پیچیده بین ویژگی‌ها، برای تحلیل داده‌های مربوط به بدهی‌ها و پیش‌بینی وضعیت پرداخت و خوددرمانی قراردادها بسیار مناسب هستند.

در این تحقیق، ویژگی‌های مختلفی مانند num\_month\_negstat (تعداد ماه‌های با وضعیت منفی) و avg\_Overdue\_to\_TotalAmount\_act\_last3m (میانگین بدهی معوق به کل بدهی در سه ماه اخیر) شناسایی شدند که تأثیر زیادی بر پیش‌بینی وضعیت قراردادها دارند. مقادیر بالاتر این ویژگی‌ها به‌طور مستقیم با SHAP Value مثبت (یعنی احتمال خوددرمانی بیشتر) مرتبط بودند، که به‌وضوح نشان‌دهنده اهمیت این ویژگی‌ها در پیش‌بینی رفتار مالی مشتریان است.

نمودارهای SHAP (SHapley Additive exPlanations) نیز به‌طور دقیق‌تر این تأثیرات را نشان می‌دهند SHAP یک ابزار قدرتمند برای تفسیر و شفاف‌سازی مدل‌های یادگیری ماشین است که نشان می‌دهد هر ویژگی چگونه بر پیش‌بینی نهایی مدل تأثیر می‌گذارد. نتایج تحلیل‌های SHAP Dependence Plot نشان داد که ویژگی‌هایی که دارای مقادیر بالاتر هستند، معمولاً تأثیر بیشتری در پیش‌بینی‌های مدل دارند و به‌ویژه به شناسایی قراردادهای خوددرمان شونده کمک می‌کنند. برای مثال، ویژگی num\_month\_negstat که نمایانگر تعداد ماه‌های با وضعیت منفی است، ارتباط مستقیمی با SHAP Value مثبت داشت که نشان‌دهنده افزایش احتمال خوددرمانی در قراردادهای دارای بدهی معوق است.

علاوه بر این، تحلیل‌های همبستگی که بر اساس ماتریس همبستگی Pearson و Spearman انجام شدند، نشان دادند که برخی ویژگی‌ها دارای همبستگی بالایی با یکدیگر هستند. به‌ویژه ویژگی‌هایی مانند num\_month\_overdue (تعداد ماه‌های تأخیر) و max\_current\_dpd (بیشترین بدهی معوق جاری) که در کنار یکدیگر می‌توانند اطلاعات دقیق‌تری درباره وضعیت بدهی‌های معوق و احتمال خوددرمانی بدهند. این همبستگی‌ها نشان‌دهنده این است که مدل‌های یادگیری ماشین قادر به شناسایی الگوهای پیچیده در داده‌ها هستند و می‌توانند به‌طور مؤثر قراردادهایی را که احتمال خوددرمانی دارند از دیگر قراردادهای تفکیک کنند.

مطالعات پیشین نیز به‌طور مشابه نشان داده‌اند که مدل‌های یادگیری ماشین، به‌ویژه مدل‌هایی که از الگوریتم‌های پیچیده برای شبیه‌سازی روابط غیرخطی و تعاملات بین ویژگی‌ها استفاده می‌کنند، می‌توانند به‌طور مؤثر رفتار مشتریان را پیش‌بینی کرده و قراردادهای خوددرمان‌شونده را شناسایی کنند. این نتایج به وضوح تأیید می‌کنند که مدل‌های یادگیری ماشین، با استفاده از ویژگی‌های مالی مرتبط و تحلیل دقیق داده‌ها، می‌توانند پیش‌بینی‌های دقیق‌تری برای مدیریت مطالبات غیرجاری ارائه دهند.

در نهایت، با توجه به تحلیل‌های انجام‌شده، به‌ویژه نتایج به‌دست‌آمده از نمودارهای SHAP و همبستگی، می‌توان نتیجه گرفت که مدل‌های یادگیری ماشین به‌طور مؤثر توانسته‌اند قدرت تفکیک بالایی در شناسایی قراردادهای خوددرمان‌شونده و پیش‌بینی وضعیت قراردادهای در ۹۰ روز آینده داشته باشند. این یافته‌ها به‌وضوح نشان می‌دهند که ویژگی‌هایی با تأثیر بالا مانند num\_month\_negstat و avg\_Overdue\_to\_TotalAmount\_act\_last3m نقش بسیار مهمی در پیش‌بینی این وضعیت‌ها دارند و می‌توانند به تفکیک دقیق‌تر قراردادهای خوددرمان‌شونده از دیگر قراردادهای کمک کنند.

تحقیق حاضر علاوه بر تأکید بر قدرت مدل‌های یادگیری ماشین در پیش‌بینی وصول مطالبات غیرجاری، بر اهمیت استفاده از روش‌های توضیح‌پذیر در این مدل‌ها تأکید دارد. با استفاده از SHAP و دیگر تکنیک‌های مشابه، توانسته‌ایم نه تنها دقت مدل‌ها را ارزیابی کنیم، بلکه میزان تأثیر هر یک از ویژگی‌ها را در تصمیم‌گیری‌های مدل شفاف‌سازی کنیم. این امر به تحلیلگران و تصمیم‌گیرندگان کمک می‌کند تا درک بهتری از نحوه عملکرد مدل داشته باشند و بتوانند به‌طور مؤثرتری از این ابزارها در تصمیم‌گیری‌های مالی استفاده کنند.

مدل‌های یادگیری ماشین به‌طور کلی در پیش‌بینی وضعیت بدهی معوق و شناسایی قراردادهای با احتمال بالا برای وصول مطالبات غیرجاری کاربرد بسیار خوبی دارند. اما چالش اصلی در استفاده از این مدل‌ها، عدم شفافیت در نحوه تصمیم‌گیری آن‌ها است. استفاده از روش‌هایی مانند SHAP به‌طور مؤثری این مشکل را حل کرده و می‌تواند بهبودهایی در دقت، تفسیرپذیری و اعتماد به مدل‌ها ایجاد کند. به‌ویژه در حوزه‌های مالی که شفافیت و دقت بالا در تصمیم‌گیری اهمیت دارد، این روش‌ها می‌توانند موجب کاهش ریسک‌ها و بهبود عملکرد سیستم‌های اعتباری شوند.

در نهایت، پژوهش حاضر نشان داد که ترکیب الگوریتم‌های یادگیری ماشین با روش‌های هوش مصنوعی توضیح‌پذیر، به‌ویژه ابزار SHAP، می‌تواند مدل‌هایی دقیق و شفاف برای پیش‌بینی وصول مطالبات غیرجاری ارائه دهد. این مدل‌ها

نه تنها در بهبود تصمیم‌گیری‌های اعتباری بانک‌ها مؤثرند، بلکه با ارتقاء قابلیت تفسیر نتایج، اعتماد مدیران و نهادهای نظارتی را نیز جلب می‌کنند. بنابراین، چنین رویکردی می‌تواند به‌عنوان گامی عملی در جهت توسعه نظام‌های هوشمند و داده‌محور در حوزه مالی مورد استفاده قرار گیرد.

برای بخش پیشنهادات پژوهش حاضر، می‌توان به موارد زیر اشاره کرد که به توسعه و بهبود مدل‌های پیش‌بینی وصول مطالبات غیرجاری مبتنی بر هوش مصنوعی توضیح‌پذیر کمک خواهد کرد:

- گسترش ویژگی‌ها و داده‌ها: در این پژوهش، برخی ویژگی‌ها مانند تعداد ماه‌های با وضعیت منفی یا میانگین بدهی معوق به کل بدهی در سه ماه اخیر نقش زیادی در پیش‌بینی‌ها ایفا کردند. پیشنهاد می‌شود که در تحقیقات آینده، ویژگی‌های بیشتری مانند تاریخچه تغییرات درآمدی، نوع قراردادها، ویژگی‌های رفتاری و اجتماعی مشتریان، یا حتی داده‌های اقتصادی کلان در نظر گرفته شوند تا مدل دقت بیشتری در پیش‌بینی‌های خود داشته باشد.
- بهبود روش‌های پردازش داده‌ها: پردازش صحیح و بهینه داده‌ها یکی از عوامل مهم در بهبود دقت مدل‌های پیش‌بینی است. پیشنهاد می‌شود که در مطالعات بعدی، از تکنیک‌های پیشرفته‌تری مانند پردازش داده‌های گم‌شده، نرمال‌سازی داده‌ها، و روش‌های بهینه‌سازی ویژگی‌ها استفاده شود تا مدل‌ها از اطلاعات بیشتری بهره‌مند شوند و خطاهای پیش‌بینی کاهش یابد.
- ارزیابی مدل‌ها در شرایط تغییرات اقتصادی و محیطی: یکی از چالش‌های مدل‌های پیش‌بینی در محیط‌های مالی، تغییرات سریع در شرایط اقتصادی و محیطی است. پیشنهاد می‌شود که مدل‌ها به‌طور مرتب به‌روز شوند و در برابر تغییرات شرایط اقتصادی مقاوم باشند. استفاده از داده‌های به‌روز و مدل‌های پویا که توانایی تطبیق با تغییرات شرایط را دارند، می‌تواند به‌طور چشمگیری عملکرد مدل‌های پیش‌بینی را بهبود بخشد.

### مشارکت نویسندگان

تمام نویسندگان به نسبت سهم برابر در این پژوهش مشارکت داشته‌اند.

### تأیید اخلاقی

رضایت کتبی آگاهانه از افراد برای انتشار اطلاعات ناشناس آنها در این مقاله اخذ شده است.

### تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

## References

- Barocas, S., Hardt, M., & Narayanan, A. (2019). *Fairness and machine learning*. Retrieved from <https://fairmlbook.org>
- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, 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>
- Basel Committee on Banking Supervision. (2017). *Guidance on the application of the core principles for effective banking supervision to the regulation and supervision of institutions relevant to financial inclusion*. Bank for International Settlements. Retrieved from <https://www.bis.org>
- Bertsimas, D., Dunn, J., & Pauphilet, J. (2020). Predicting bankruptcies with machine learning. *Management Science*, 66(12), 5461–5480. <https://doi.org/10.1287/mnsc.2019.3480>
- BIS. (2020). *Credit risk and credit risk mitigation*. Bank for International Settlements. Retrieved from <https://www.bis.org>
- Bradley, A. P. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7), 1145–1159. [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2)
- Brownlee, J. (2020). *Imbalanced classification with Python: Better metrics, balance skewed classes, cost-sensitive learning*. Machine Learning Mastery.
- Brynjolfsson, E., & McAfee, A. (2017). *Machine, platform, crowd: Harnessing our digital future*. W.W. Norton & Company.
- Cont, R. (2001). Empirical properties of asset returns: Stylized facts and statistical issues. *Quantitative Finance*, 1(2), 223–236. <https://doi.org/10.1080/713665670>
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. *arXiv preprint arXiv:1702.08608*. <https://arxiv.org/abs/1702.08608>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Hamilton, J. D. (1989). A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, 57(2), 357–384. <https://doi.org/10.2307/1912559>
- He, H., & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263–1284. <https://doi.org/10.1109/TKDE.2008.239>
- Hassanzadeh, Hossein and Habibi, Milad (2010), Dissection of Overdue Claims. *Banking Journal*. 4(14).
- Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, 34(11), 2767–2787. <https://doi.org/10.1016/j.jbankfin.2010.06.001>
- Lessmann, S., Baesens, B., Seow, H. V., & Thomas, L. C. (2015). Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, 247(1), 124–136. <https://doi.org/10.1016/j.ejor.2015.05.030>
- Lipton, Z. C. (2018). The mythos of model interpretability. *Communications of the ACM*, 61(10), 36–43. <https://doi.org/10.1145/3233231>
- Liu, Y., Lei, Z., Liu, Z., & Yang, J. (2020). Predicting consumer loan default with deep learning: A comparative study. *Expert Systems with Applications*, 144, 113092. <https://doi.org/10.1016/j.eswa.2019.113092>
- Louzis, D. P., Vouldis, A. T., & Metaxas, V. L. (2012). Macroeconomic and bank-specific determinants of non-performing loans in Greece: A comparative study of mortgage, business and consumer loan portfolios. *Journal of Banking & Finance*, 36(4), 1012–1027. <https://doi.org/10.1016/j.jbankfin.2011.10.012>
- Messai, A. S., & Jouini, F. (2013). Micro and macro determinants of non-performing loans. *International Journal of Economics and Financial Issues*, 3(4), 852–860.

- Reddy, Y. V. (2002). Non-performing loans—some issues. *Banking Sector Reforms in India*, 68–78.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?” Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135–1144. <https://doi.org/10.1145/2939672.2939778>
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
- Serrano-Cinca, C., Gutiérrez-Nieto, B., & López-Palacios, L. (2015). Determinants of default in P2P lending. *PLOS ONE*, 10(10), e0139427. <https://doi.org/10.1371/journal.pone.0139427>
- Taleb, N. N. (2007). *The black swan: The impact of the highly improbable*. Random House.
- Tsay, R. S. (2010). *Analysis of financial time series* (Vol. 543). John Wiley & Sons.
- Zhang, D., Zhou, L., & Du, J. (2020). Exploring the nonlinear relationship between credit risk and firm performance. *Journal of Business Research*, 109, 244–256. <https://doi.org/10.1016/j.jbusres.2019.11.064>
- Zhang, X., Wang, H., & Zhu, J. (2021). An explainable machine learning model for predicting loan default risk. *Applied Intelligence*, 51, 4432–4445. <https://doi.org/10.1007/s10489-020-02020-3>

