



# Explainable Credit Scoring Model for Bank Customers Using SHAP and Machine Learning Based on Behavioral Features

Kian Maleki<sup>1\*</sup>, Narges Taheri<sup>2</sup>, Amirhossein Rastgar<sup>3</sup>

<sup>1</sup> Master of Science in Financial Management, Ferdowsi University of Mashhad, Mashhad, Iran (Corresponding author), Email: k.maleki@stu.um.ac.ir

<sup>2</sup> Master of Science in Financial Management, Ferdowsi University of Mashhad, Mashhad, Iran

<sup>3</sup> Bachelor of Accounting, Ferdowsi University of Mashhad, Mashhad, Iran

## ARTICLE INFO

### Article history:

Received:05/06/2025

Received in revised form:16/07/2025

Accepted:01/08/2025

Available online:16/08/2025

### Keywords:

Machine Learning

Credit Scoring

SHAP

Credit Risk

Customer Behavioral Features

## ABSTRACT

In recent years, banking systems have faced a significant increase in both the volume and complexity of customer financial data. As a result, traditional credit scoring methods based on linear assumptions and limited indicators have become less effective. Machine learning techniques have therefore emerged as powerful tools for credit risk assessment due to their ability to capture complex nonlinear relationships in large datasets. However, a major limitation of these models is their lack of interpretability, which restricts their practical use in regulated banking environments. This study proposes an explainable credit scoring framework by integrating machine learning models with SHAP. Behavioral features such as transaction patterns, debt levels, repayment history, and other customer-related indicators are used to build predictive models. Algorithms including Random Forest, Gradient Boosting Machines, and Support Vector Machines are applied to evaluate credit risk prediction performance. SHAP is then used to interpret model outputs and quantify the contribution of each feature.

The results show that repayment history, debt-to-income ratio, and transaction behavior are the most influential factors in determining credit scores. The integration of SHAP with machine learning not only maintains high predictive accuracy but also significantly improves model transparency and interpretability. Overall, the proposed approach enhances trust, fairness, and accountability in credit scoring systems and provides a strong foundation for future research in explainable financial analytics.

## Article Type: Research Paper

*Journal of Intelligent Financial Management*,  
2025, Vol. 1, No.2, pp. 42- 55



### Publish by:

Tolou-e Binish-e Ayandeh Scientific Institute

©Authors

<https://doi.org/10.25843/JIFM.2025.8563.32584>

**Cite:** Maleki,K, Taheri,N and Rastgar,A. (2025). Explainable Credit Scoring Model for Bank Customers Using SHAP and Machine Learning Based on Behavioral Features. *Journal of Intelligent Financial Management*, 1(2), 42-55.



# مدل توضیح‌پذیر رتبه‌بندی اعتباری مشتریان بانک با استفاده از SHAP و یادگیری ماشین مبتنی بر ویژگی‌های رفتاری

کیان ملکی<sup>۱\*</sup>، نرگس طاهری<sup>۲</sup>، امیر حسین رستگاری<sup>۳</sup>

۱ - کارشناسی ارشد مدیریت مالی، دانشگاه فردوسی مشهد، مشهد، ایران (نویسنده مسئول)، ایمیل نویسنده مسئول: [k.maleki@stu.um.ac.ir](mailto:k.maleki@stu.um.ac.ir)

۲ - کارشناسی ارشد مدیریت مالی، دانشگاه فردوسی مشهد، مشهد، ایران

۳ - کارشناسی حسابداری، دانشگاه فردوسی مشهد، مشهد، ایران

## اطلاعات مقاله

### تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۴/۰۳/۱۵

تاریخ بازنگری: ۱۴۰۴/۰۴/۲۵

تاریخ پذیرش: ۱۴۰۴/۰۵/۱۰

تاریخ انتشار: ۱۴۰۴/۰۵/۲۵

### کلیدواژه‌ها:

یادگیری ماشین

رتبه بندی اعتباری

SHAP

ریسک اعتباری

ویژگی رفتار مشتریان

## چکیده

در سال‌های اخیر، سیستم‌های بانکی با افزایش قابل توجه حجم و پیچیدگی داده‌های مالی مشتریان مواجه شده‌اند. این موضوع باعث شده است روش‌های سنتی اعتبارسنجی که بر شاخص‌های محدود و فرضیات خطی تکیه دارند، کارایی کمتری داشته باشند. در نتیجه، روش‌های یادگیری ماشین به دلیل توانایی در مدل‌سازی روابط غیرخطی و پیچیده، به ابزارهای مهمی در ارزیابی ریسک اعتباری تبدیل شده‌اند. با این حال، مشکل اصلی این مدل‌ها عدم شفافیت و تفسیرپذیری آن‌هاست که استفاده عملی از آن‌ها را در محیط‌های بانکی و تحت مقررات محدود می‌کند.

در این پژوهش، یک چارچوب اعتبارسنجی توضیح‌پذیر با ترکیب الگوریتم‌های یادگیری ماشین و روش SHAP ارائه شده است. در این مدل، از ویژگی‌های رفتاری مشتریان مانند الگوی تراکنش‌ها، سطح بدهی، سابقه بازپرداخت و شاخص‌های مرتبط استفاده شده و مدل‌هایی مانند Random Forest، Gradient Boosting و SVM برای پیش‌بینی ریسک اعتباری به کار گرفته شده‌اند. سپس SHAP برای تفسیر نتایج و تعیین میزان تأثیر هر ویژگی بر خروجی مدل استفاده شده است. نتایج نشان می‌دهد که ویژگی‌هایی مانند سابقه بازپرداخت، نسبت بدهی به درآمد و رفتار تراکنشی از مهم‌ترین عوامل در تعیین امتیاز اعتباری هستند. همچنین ترکیب یادگیری ماشین با SHAP علاوه بر حفظ دقت بالا، موجب افزایش شفافیت و تفسیرپذیری مدل می‌شود. در مجموع، این رویکرد می‌تواند اعتماد، عدالت و پاسخ‌گویی در سیستم‌های اعتبارسنجی را بهبود دهد و پایه‌ای برای تحقیقات آینده در حوزه تحلیل مالی توضیح‌پذیر فراهم کند.

## نوع مقاله: پژوهشی



## © نویسندگان

استناد: ملکی، کیان، طاهری، نرگس و رستگار، امیر حسین. (۱۴۰۴). مدل توضیح‌پذیر رتبه‌بندی اعتباری مشتریان بانک با استفاده از SHAP و یادگیری ماشین مبتنی بر ویژگی‌های رفتاری. *مدیریت مالی هوشمند*، ۲(۱)، ۴۲-۵۵.

نشریه مدیریت مالی هوشمند، ۱۴۰۴، دوره ۱، شماره ۲، صفحه ۴۲-۵۵.

ناشر: موسسه علمی طلوع بینش آینده

<https://doi.org/10.25843/JIFM.2025.8563.32584>

## ۱- مقدمه

گسترش روزافزون در دهه‌های اخیر، نظام‌های بانکی در سراسر جهان با تحولات بنیادینی در حوزه فناوری اطلاعات، تحلیل داده و مدیریت ریسک مواجه شده‌اند. رشد سریع حجم داده‌های تولیدشده از تعاملات مالی مشتریان، توسعه بانکداری دیجیتال، و گسترش خدمات مالی آنلاین موجب شده است که بانک‌ها با انبوهی از داده‌های ساخت‌یافته و غیرساخت‌یافته روبه‌رو شوند که تحلیل آن‌ها با روش‌های سنتی آماری به‌تنهایی امکان‌پذیر یا کافی نیست. در چنین شرایطی، اهمیت استفاده از روش‌های نوین داده‌محور برای تحلیل رفتار مشتریان و پیش‌بینی ریسک اعتباری بیش از پیش برجسته شده است. یکی از مهم‌ترین حوزه‌هایی که تحت تأثیر این تحول قرار گرفته، نظام‌های اعتبارسنجی مشتریان بانک است که نقش کلیدی در تصمیم‌گیری‌های اعطای تسهیلات و مدیریت ریسک ایفا می‌کند.

در گذشته، مدل‌های اعتبارسنجی عمدتاً مبتنی بر روش‌های آماری کلاسیک مانند رگرسیون لجستیک، تحلیل ممیزی خطی و امتیازدهی مبتنی بر قواعد تجربی بودند. این مدل‌ها با وجود سادگی و قابلیت تفسیر نسبی، دارای محدودیت‌های جدی در مواجهه با داده‌های پیچیده و غیرخطی بودند. به‌ویژه زمانی که روابط میان متغیرهای مالی و رفتاری مشتریان پیچیده و چندبعدی می‌شد، این روش‌ها توانایی کافی برای شناسایی الگوهای پنهان در داده‌ها را نداشتند (Henley (1997). بیان می‌کنند که روش‌های سنتی اعتبارسنجی اگرچه در دوره‌ای کارآمد بودند، اما با افزایش پیچیدگی رفتار مالی مشتریان، کارایی خود را تا حد زیادی از دست داده‌اند.

با ورود به عصر داده‌های بزرگ و پیشرفت توان محاسباتی، یادگیری ماشین به‌عنوان یک رویکرد قدرتمند برای تحلیل داده‌های پیچیده وارد حوزه مالی شد. الگوریتم‌های یادگیری ماشین توانایی بالایی در شناسایی روابط غیرخطی، تعاملات پیچیده میان متغیرها و استخراج الگوهای پنهان دارند. الگوریتم‌هایی مانند جنگل تصادفی، ماشین‌های تقویت گرادیانی، شبکه‌های عصبی و ماشین بردار پشتیبان توانسته‌اند عملکرد بسیار بهتری نسبت به مدل‌های کلاسیک در پیش‌بینی ریسک اعتباری ارائه دهند. مطالعات مختلف نشان داده‌اند که استفاده از این الگوریتم‌ها می‌تواند دقت پیش‌بینی نکول مشتریان را به‌طور قابل توجهی افزایش دهد. (Lessmann et al., 2015) این پیشرفت‌ها موجب شده است که یادگیری ماشین به یکی از ابزارهای اصلی در تحلیل ریسک اعتباری تبدیل شود.

با این حال، علی‌رغم افزایش دقت پیش‌بینی در مدل‌های یادگیری ماشین، یک چالش اساسی همچنان باقی مانده است و آن مسئله عدم تفسیرپذیری یا «جعبه سیاه بودن» این مدل‌ها است. بسیاری از الگوریتم‌های پیشرفته، اگرچه پیش‌بینی‌های دقیقی ارائه می‌دهند، اما توضیح روشنی درباره اینکه چرا یک تصمیم خاص اتخاذ شده است ارائه نمی‌کنند. این موضوع در حوزه بانکداری که تصمیمات مالی باید قابل توضیح، قابل نظارت و مطابق با مقررات قانونی باشند، اهمیت بسیار زیادی دارد. در واقع، نهادهای نظارتی و مدیران بانکی نیاز دارند بدانند که چرا یک مشتری در دسته پرریسک یا کم‌ریسک قرار گرفته است. نبود این شفافیت می‌تواند منجر به کاهش اعتماد به سیستم‌های هوشمند، افزایش ریسک حقوقی و حتی ایجاد تبعیض‌های ناخواسته در تصمیم‌گیری شود.

در پاسخ به این چالش، حوزه هوش مصنوعی توضیح‌پذیر (XAI - Explainable Artificial Intelligence) توسعه یافته است. هدف اصلی این حوزه، ایجاد مدل‌هایی است که علاوه بر ارائه پیش‌بینی‌های دقیق، بتوانند دلایل تصمیم‌گیری خود را نیز به‌صورت قابل فهم برای انسان توضیح دهند. Doshi-Velez و Kim (2017) تأکید می‌کنند که توسعه مدل‌های قابل تفسیر نه تنها یک ضرورت علمی بلکه یک الزام اخلاقی در کاربردهای حساس مانند مالی و پزشکی است. در میان روش‌های مختلف ارائه‌شده در حوزه XAI روش SHAP (SHapley Additive

exPlanations) یکی از جامع‌ترین و نظری‌ترین رویکردها محسوب می‌شود. روش SHAP بر پایه نظریه بازی‌های مشارکتی توسعه یافته است و تلاش می‌کند سهم هر ویژگی را در خروجی نهایی مدل به‌صورت عادلانه و دقیق محاسبه کند. (Lee (2017) نشان دادند که این روش می‌تواند یک چارچوب یکپارچه برای تفسیر مدل‌های یادگیری ماشین ارائه دهد، به‌گونه‌ای که هم قابلیت تفسیر محلی و هم قابلیت تفسیر کلی را فراهم کند. در تفسیر محلی، می‌توان توضیح داد که چرا یک مشتری خاص

به‌عنوان پرریسک یا کم‌ریسک طبقه‌بندی شده است، در حالی که در تفسیر کلی، می‌توان فهمید کدام ویژگی‌ها به‌طور کلی بیشترین تأثیر را بر مدل دارند. این قابلیت‌ها باعث شده است SHAP به یکی از ابزارهای مهم در تحلیل مدل‌های پیچیده مالی تبدیل شود. در کنار توسعه روش‌های یادگیری ماشین و XAI، نوع داده‌های مورد استفاده در مدل‌های اعتبارسنجی نیز دچار تحول شده است. در گذشته، داده‌های دموگرافیک مانند سن، جنسیت، درآمد و وضعیت شغلی نقش اصلی را در مدل‌های اعتبارسنجی داشتند. اما در سال‌های اخیر، تمرکز به سمت داده‌های رفتاری مشتریان تغییر یافته است. داده‌های رفتاری شامل الگوهای تراکنش‌های بانکی، نحوه استفاده از حساب، میزان و نحوه بازپرداخت تسهیلات، رفتار مصرفی و حتی الگوهای زمانی تراکنش‌ها است. (Khandani et al. (2010 نشان دادند که استفاده از داده‌های رفتاری در مقایسه با داده‌های سنتی می‌تواند دقت مدل‌های پیش‌بینی ریسک اعتباری را به‌طور قابل توجهی افزایش دهد. دلیل این امر آن است که رفتار مالی واقعی مشتریان در طول زمان، تصویر دقیق‌تری از توان بازپرداخت و میزان ریسک آن‌ها ارائه می‌دهد. ترکیب داده‌های رفتاری با الگوریتم‌های یادگیری ماشین، امکان ساخت مدل‌هایی را فراهم می‌کند که قادرند الگوهای پیچیده پنهان در رفتار مشتریان را شناسایی کنند. برای مثال، تغییرات ناگهانی در الگوی تراکنش‌ها، افزایش بدهی نسبت به درآمد یا کاهش تدریجی موجودی حساب می‌تواند نشانه‌هایی از افزایش ریسک اعتباری باشد. الگوریتم‌های یادگیری ماشین قادرند این الگوها را شناسایی کرده و احتمال نکول را با دقت بالا پیش‌بینی کنند. با این حال، همان‌طور که اشاره شد، این پیش‌بینی‌ها بدون توضیح باقی می‌مانند مگر اینکه با روش‌های توضیح‌پذیر ترکیب شوند.

در این میان، ترکیب یادگیری ماشین با SHAP یک رویکرد قدرتمند برای حل همزمان دو مسئله دقت و تفسیرپذیری ارائه می‌دهد. این ترکیب به تحلیل‌گران بانکی اجازه می‌دهد نه تنها بدانند که یک مشتری در چه سطحی از ریسک قرار دارد، بلکه بفهمند کدام ویژگی‌ها بیشترین نقش را در این تصمیم داشته‌اند. این موضوع در تصمیم‌گیری‌های اعتباری بسیار مهم است، زیرا بانک‌ها باید بتوانند دلایل رد یا پذیرش درخواست تسهیلات را به‌صورت شفاف ارائه دهند. همچنین، این شفافیت می‌تواند به کاهش تبعیض‌های الگوریتمی کمک کند، زیرا امکان بررسی تأثیر هر ویژگی فراهم می‌شود.

مطالعات اخیر نشان داده‌اند که مدل‌های ترکیبی یادگیری ماشین و SHAP می‌توانند عملکرد بسیار خوبی در حوزه اعتبارسنجی داشته باشند. برای مثال، Lessmann et al. (2015) در بررسی تطبیقی الگوریتم‌های مختلف نشان دادند که مدل‌های مبتنی بر روش‌های تجمعی مانند تقویت گرادیانی و جنگل تصادفی عملکرد بسیار بالایی در پیش‌بینی ریسک دارند. در ادامه، تحقیقات جدیدتر نشان داده‌اند که افزودن لایه تفسیرپذیری به این مدل‌ها نه تنها عملکرد آن‌ها را کاهش نمی‌دهد، بلکه موجب بهبود اعتمادپذیری و کاربردپذیری آن‌ها در محیط‌های واقعی می‌شود (Molnar, 2020).

از منظر کاربردی، بانک‌ها به دنبال سیستم‌هایی هستند که بتوانند همزمان سه ویژگی کلیدی داشته باشند: دقت بالا، سرعت پردازش مناسب و قابلیت توضیح تصمیمات. مدل‌های سنتی تنها قابلیت توضیح داشتند اما دقت کافی نداشتند. مدل‌های یادگیری ماشین دقت بالایی دارند اما توضیح‌پذیر نیستند. رویکردهای ترکیبی مانند SHAP تلاش می‌کنند این شکاف را پر کنند و یک تعادل میان این سه ویژگی ایجاد نمایند. این موضوع به‌ویژه در چارچوب مقررات مالی بین‌المللی اهمیت دارد، زیرا بسیاری از نهادهای نظارتی بانک‌ها را ملزم به ارائه دلایل شفاف برای تصمیمات اعتباری می‌کنند.

در نهایت، می‌توان گفت که توسعه مدل‌های توضیح‌پذیر در اعتبارسنجی بانکی نه تنها یک پیشرفت تکنولوژیک بلکه یک ضرورت عملی و اخلاقی است. استفاده از داده‌های رفتاری، الگوریتم‌های یادگیری ماشین و روش‌های تفسیرپذیر مانند SHAP، مسیر جدیدی را در مدیریت ریسک اعتباری ایجاد کرده است. این مسیر امکان ایجاد سیستم‌هایی را فراهم می‌کند که هم دقیق هستند و هم قابل اعتماد، هم قدرتمند هستند و هم قابل توضیح. پژوهش حاضر در همین راستا تلاش می‌کند مدلی ارائه دهد که بتواند با استفاده از ویژگی‌های رفتاری مشتریان و الگوریتم‌های یادگیری ماشین، رتبه‌بندی اعتباری را با دقت بالا انجام دهد و در عین حال با استفاده از SHAP، شفافیت کامل در فرآیند تصمیم‌گیری ایجاد کند.

## ۲- مبانی نظری و پیشینه تحقیق

ادبیات پژوهش در حوزه اعتبارسنجی اعتباری طی چند دهه اخیر تحولات گسترده‌ای را تجربه کرده است که ریشه آن را می‌توان در تغییر ماهیت داده‌ها، پیشرفت توان محاسباتی و ظهور رویکردهای داده‌محور در علوم مالی جستجو کرد. اعتبارسنجی اعتباری به‌عنوان یکی از مهم‌ترین

ابزارهای مدیریت ریسک در نظام بانکی، همواره نقش اساسی در تصمیم‌گیری‌های مرتبط با اعطای تسهیلات، تعیین نرخ بهره، مدیریت پرتفوی اعتباری و کنترل ریسک نکول داشته است. در ادبیات کلاسیک، مدل‌های اعتبارسنجی عمدتاً بر پایه روش‌های آماری ساده و قابل تفسیر بنا شده بودند که مهم‌ترین آن‌ها شامل رگرسیون لجستیک، تحلیل ممیزی خطی و سیستم‌های امتیازدهی دستی مبتنی بر وزن‌دهی خطی متغیرها بوده است. این مدل‌ها به دلیل سادگی، قابلیت توضیح‌پذیری و سهولت پیاده‌سازی در دهه‌های گذشته به‌طور گسترده در صنعت بانکداری مورد استفاده قرار گرفتند. با این حال، با افزایش پیچیدگی رفتار مشتریان و رشد داده‌های غیرخطی و چندبعدی، محدودیت‌های این رویکردها به تدریج آشکار شد. (Henley (1997 از نخستین پژوهشگرانی بودند که به‌طور نظام‌مند نشان دادند مدل‌های سنتی اعتبارسنجی در مواجهه با روابط پیچیده میان متغیرهای مالی و رفتاری مشتریان، توانایی کافی برای پیش‌بینی دقیق ریسک نکول ندارند و در بسیاری از موارد منجر به کاهش کارایی سیستم‌های تصمیم‌گیری اعتباری می‌شوند.

با ورود به عصر داده‌های بزرگ و توسعه زیرساخت‌های محاسباتی، رویکردهای مبتنی بر یادگیری ماشین به‌عنوان جایگزینی قدرتمند برای مدل‌های کلاسیک مطرح شدند. یادگیری ماشین توانایی قابل توجهی در شناسایی روابط غیرخطی، تعاملات پیچیده و الگوهای پنهان در داده‌های حجیم دارد. الگوریتم‌هایی مانند جنگل تصادفی، گرادیان بوسستینگ، ماشین بردار پشتیبان و شبکه‌های عصبی مصنوعی به‌طور گسترده در حوزه اعتبارسنجی اعتباری مورد استفاده قرار گرفته‌اند. (Lessmann et al. (2015 در یک مطالعه جامع نشان دادند که الگوریتم‌های یادگیری ماشین به‌طور معناداری عملکرد بهتری نسبت به مدل‌های کلاسیک در پیش‌بینی ریسک اعتباری دارند و می‌توانند نرخ خطای طبقه‌بندی را در بسیاری از دیتاست‌های مالی کاهش دهند. این یافته‌ها موجب شد که استفاده از مدل‌های پیشرفته یادگیری ماشین در صنعت بانکداری به‌سرعت گسترش یابد.

با وجود این پیشرفت‌ها، یکی از چالش‌های اساسی در استفاده از مدل‌های یادگیری ماشین در حوزه مالی، مسئله تفسیرپذیری یا همان “black-box problem” است. بسیاری از الگوریتم‌های پیشرفته اگرچه دقت بالایی دارند، اما قادر به ارائه توضیح شفاف درباره دلایل تصمیم‌گیری خود نیستند. این موضوع در حوزه بانکداری که تصمیمات باید مطابق با مقررات، قابل توضیح برای مشتری و قابل دفاع در برابر نهادهای نظارتی باشد، اهمیت بسیار بالایی دارد. در واقع، نبود شفافیت در مدل‌های پیچیده می‌تواند منجر به کاهش اعتماد کاربران، افزایش ریسک قانونی و ایجاد چالش در انطباق با مقررات شود. (Doshi-Velez و Kim (2017 تأکید می‌کنند که تفسیرپذیری در مدل‌های یادگیری ماشین نه یک ویژگی اختیاری، بلکه یک ضرورت در کاربردهای حساس مانند مالی و پزشکی است.

در پاسخ به این چالش، حوزه هوش مصنوعی توضیح‌پذیر (Explainable Artificial Intelligence – XAI) شکل گرفته است که هدف آن ایجاد روش‌هایی برای توضیح تصمیمات مدل‌های پیچیده یادگیری ماشین است. در میان روش‌های مختلف XAI، دو روش SHAP و LIME از مهم‌ترین و پرکاربردترین تکنیک‌ها محسوب می‌شوند. روش LIME تلاش می‌کند رفتار مدل پیچیده را در اطراف یک نمونه خاص با استفاده از یک مدل ساده محلی تقریب بزند، در حالی که SHAP بر پایه نظریه بازی‌های مشارکتی توسعه یافته و سهم هر ویژگی را در خروجی مدل به‌صورت عادلانه و ریاضی‌محور محاسبه می‌کند. تفاوت بنیادی این دو روش در سطح نظریه‌ای و ثبات توضیحات آن‌هاست. مطالعات نشان داده‌اند که SHAP از نظر انسجام نظری و پایداری نتایج نسبت به LIME برتری دارد، در حالی که LIME از نظر سرعت محاسباتی و سادگی پیاده‌سازی در برخی کاربردها مناسب‌تر است. (Gramegna & Giudici, 2021) در ادبیات پژوهشی جدید، مطالعات متعددی نشان داده‌اند که روش SHAP به دلیل بهره‌گیری از ارزش‌های شاپلی، توانایی ارائه توضیحات در دو سطح سراسری و موضعی را به‌طور هم‌زمان داراست. به بیان دیگر، این روش علاوه بر تبیین عملکرد کلی مدل و میزان اهمیت متغیرها در سطح کلان، قادر است نقش هر متغیر را در پیش‌بینی هر مشاهده به‌صورت جداگانه نیز مشخص کند. در مقابل، روش LIME عمدتاً بر ارائه توضیحات در سطح موضعی تمرکز دارد و برای تفسیر پیش‌بینی‌های منفرد مورد استفاده قرار می‌گیرد. در سال‌های اخیر، استفاده از روش‌های XAI در صنعت بانکداری رشد قابل توجهی داشته است. بانک‌ها و مؤسسات مالی به‌طور فزاینده‌ای از مدل‌های ترکیبی الگوریتم‌هایی مانند Gradient Boosting و LightGBM با SHAP می‌توانند هم‌زمان دقت بالا و قابلیت تفسیر مناسب را فراهم کنند. برای مثال، پژوهش‌های اخیر نشان می‌دهند که استفاده از SHAP در مدل‌های تقویتی نه تنها امکان تحلیل دقیق ویژگی‌های مؤثر بر ریسک اعتباری را فراهم می‌کند، بلکه به بهبود اعتماد تصمیم‌گیرندگان نیز کمک می‌کند. (Bücker et al., 2020)

همچنین در برخی مطالعات، مدل‌های مبتنی بر LightGBM همراه با SHAP توانسته‌اند عملکرد بهتری نسبت به مدل‌های کلاسیک مانند رگرسیون لجستیک داشته باشند و در عین حال قابلیت توضیح‌پذیری مناسبی ارائه دهند.

یکی از مهم‌ترین تحولات در ادبیات اعتبارسنجی، تغییر تمرکز از داده‌های سنتی دموگرافیک به داده‌های رفتاری مشتریان است. داده‌های رفتاری شامل الگوهای تراکنش، تاریخچه بازپرداخت، رفتار مصرفی، نسبت بدهی به درآمد و تغییرات زمانی در فعالیت‌های مالی مشتریان است. برخلاف ویژگی‌های دموگرافیک که اغلب ایستا هستند، داده‌های رفتاری ماهیت پویا دارند و اطلاعات دقیق‌تری از وضعیت مالی واقعی مشتری ارائه می‌دهند. (Khandani et al. (2010 نشان دادند که استفاده از داده‌های رفتاری در مدل‌های یادگیری ماشین می‌تواند دقت پیش‌بینی نکول را به‌طور قابل توجهی افزایش دهد. این یافته‌ها موجب شد که بسیاری از بانک‌ها به سمت استفاده از داده‌های رفتاری به‌عنوان ورودی اصلی مدل‌های اعتبارسنجی حرکت کنند.

در کنار این پیشرفت‌ها، یکی از مباحث مهم در ادبیات XAI، مسئله سوگیری الگوریتمی و عدالت در تصمیم‌گیری‌های اعتباری است. مدل‌های یادگیری ماشین ممکن است به‌طور ناخواسته الگوهای تبعیض‌آمیز موجود در داده‌های تاریخی را یاد بگیرند و آن‌ها را در تصمیمات جدید بازتولید کنند. این مسئله به‌ویژه در حوزه اعطای وام و خدمات مالی حساسیت بالایی دارد، زیرا می‌تواند منجر به تصمیمات ناعادلانه شود. روش‌های توضیح‌پذیر مانند SHAP نقش مهمی در شناسایی این سوگیری‌ها دارند، زیرا امکان تحلیل سهم هر ویژگی در تصمیم مدل را فراهم می‌کنند. (Molnar (2020 بیان می‌کند که تفسیرپذیری نه تنها ابزار افزایش شفافیت، بلکه ابزاری برای کنترل عدالت الگوریتمی است.

از منظر مقررات‌گذاری و نظارت مالی، نهادهای بین‌المللی نظیر کمیته بال و مقررات عمومی حفاظت از داده‌ها در اتحادیه اروپا بر ضرورت شفافیت و توضیح‌پذیری مدل‌های اعتبارسنجی تأکید ویژه‌ای دارند. بر اساس این الزامات، مؤسسات مالی موظف‌اند در صورت رد درخواست تسهیلات یا اعتبار، دلایل این تصمیم را به شکلی روشن و قابل فهم برای متقاضیان ارائه کنند. این موضوع موجب شده است که استفاده از مدل‌های پیچیده و غیرشفاف، بدون بهره‌گیری از ابزارهای تفسیرپذیری، در بسیاری از کشورها با محدودیت‌های قانونی و نظارتی مواجه شود. در نتیجه، به‌کارگیری روش‌های توضیح‌پذیری مانند SHAP و LIME در کنار مدل‌های یادگیری ماشین، به یک ضرورت عملی برای افزایش شفافیت، جلب اعتماد ذی‌نفعان و رعایت الزامات نظارتی تبدیل شده است. در ادبیات ۲۰۲۰ تا ۲۰۲۵، روند پژوهش‌ها نشان‌دهنده حرکت به سمت مدل‌های ترکیبی است که همزمان سه هدف اصلی را دنبال می‌کنند: افزایش دقت پیش‌بینی، افزایش شفافیت و رعایت الزامات رگولاتوری. مطالعات جدید نشان می‌دهند که مدل‌های ensemble مانند Random Forest، XGBoost و LightGBM در ترکیب با SHAP عملکرد بسیار مطلوبی در حوزه اعتبارسنجی دارند. همچنین پژوهش‌های اخیر نشان می‌دهند که استفاده از XAI در بانکداری نه تنها یک ابزار تحلیلی، بلکه یک ابزار استراتژیک برای افزایش اعتماد مشتریان و کاهش ریسک عملیاتی محسوب می‌شود. در برخی کاربردهای صنعتی، بانک‌ها از SHAP برای تولید "reason codes" استفاده می‌کنند که به مشتری توضیح می‌دهد چرا درخواست او رد یا قبول شده است.

در نهایت، جمع‌بندی ادبیات پژوهش نشان می‌دهد که حوزه اعتبارسنجی اعتباری در حال گذار از مدل‌های ساده و قابل تفسیر به سمت مدل‌های پیچیده و داده‌محور است، اما این گذار با نیاز فزاینده به توضیح‌پذیری همراه شده است. ترکیب یادگیری ماشین با روش‌های XAI به‌ویژه SHAP و LIME، یک چارچوب نوین برای ایجاد تعادل بین دقت و شفافیت فراهم کرده است. این چارچوب امکان استفاده از قدرت پیش‌بینی مدل‌های پیشرفته را در کنار حفظ قابلیت تفسیر و انطباق با مقررات فراهم می‌کند. در نتیجه، پژوهش حاضر در امتداد این جریان علمی تلاش دارد مدلی ارائه دهد که بتواند با استفاده از ویژگی‌های رفتاری مشتریان و الگوریتم‌های یادگیری ماشین، رتبه‌بندی اعتباری دقیق و در عین حال توضیح‌پذیر ارائه دهد و شکاف میان عملکرد الگوریتمی و نیازهای انسانی و رگولاتوری را کاهش دهد.

## ۲-۱ پیشینه تحقیقات

مطالعات مرتبط با اعتبارسنجی اعتباری و پیش‌بینی ریسک نکول در نظام‌های بانکی، سابقه‌ای چند دهه‌ای دارند و می‌توان گفت این حوزه یکی از نخستین کاربردهای تحلیل داده در علوم مالی محسوب می‌شود. در ادبیات کلاسیک، پژوهش‌ها عمدتاً بر مدل‌های آماری مانند رگرسیون لجستیک، تحلیل ممیزی خطی و مدل‌های امتیازدهی اعتباری متمرکز بودند. این مدل‌ها به دلیل سادگی و قابلیت تفسیر بالا، سال‌ها در بانک‌ها و مؤسسات مالی مورد استفاده قرار گرفتند. با این حال، همان‌طور که (Henley (1997 اشاره کرده‌اند، این مدل‌ها در مواجهه با روابط غیرخطی و پیچیده میان متغیرهای مالی و رفتاری مشتریان، توانایی محدودی دارند و در بسیاری از موارد قادر به استخراج الگوهای پنهان در داده‌های واقعی نیستند. این محدودیت‌ها زمینه را برای ورود رویکردهای پیشرفته‌تر فراهم کرد.

با ورود به دهه ۲۰۱۰ و رشد داده‌های بزرگ، یادگیری ماشین به‌عنوان رویکرد غالب در بسیاری از مسائل طبقه‌بندی از جمله اعتبارسنجی اعتباری مطرح شد. پژوهش‌های (Lessmann et al. (2015 یکی از جامع‌ترین مطالعات در این حوزه محسوب می‌شود که نشان داد الگوریتم‌های یادگیری ماشین مانند Random Forest، Gradient Boosting Machines و Support Vector Machines عملکرد بهتری نسبت به مدل‌های کلاسیک در پیش‌بینی ریسک اعتباری دارند. این مطالعه نقطه عطفی در ادبیات محسوب می‌شود، زیرا نشان داد که افزایش پیچیدگی مدل‌ها می‌تواند بهبود معناداری در دقت پیش‌بینی ایجاد کند، هرچند این بهبود با هزینه کاهش تفسیرپذیری همراه است.

در سال‌های اخیر، تمرکز پژوهش‌ها از صرفاً افزایش دقت به سمت ایجاد تعادل میان دقت و تفسیرپذیری تغییر یافته است. این تغییر پارادایم با ظهور مفهوم هوش مصنوعی توضیح‌پذیر همراه بوده است. Doshi-Velez و Kim (2017) از نخستین پژوهشگرانی بودند که چارچوبی مفهومی برای ضرورت تفسیرپذیری در مدل‌های یادگیری ماشین ارائه کردند و تأکید داشتند که در حوزه‌های حساس مانند مالی، سلامت و حقوق، عدم شفافیت مدل‌ها می‌تواند پیامدهای جدی اخلاقی و قانونی داشته باشد.

در این میان، روش‌های مختلفی برای تفسیر مدل‌های یادگیری ماشین توسعه یافته‌اند که دو مورد از مهم‌ترین آن‌ها SHAP و LIME هستند. LIME تلاش می‌کند رفتار مدل پیچیده را در اطراف یک نمونه خاص با استفاده از یک مدل خطی ساده تقریب بزند. در مقابل، SHAP بر پایه نظریه بازی‌های مشارکتی بنا شده و سهم هر ویژگی را در خروجی مدل به‌صورت عادلانه و مبتنی بر ارزش شاپلی محاسبه می‌کند. مطالعات مقایسه‌ای نشان داده‌اند که SHAP از نظر پایداری، انسجام نظری و قابلیت تفسیر جهانی و محلی نسبت به LIME برتری دارد، در حالی که LIME از نظر سرعت محاسباتی در برخی کاربردهای سبک‌تر مناسب‌تر است (Gramegna & Giudici, 2021).

در پژوهش‌های جدید بین‌المللی، استفاده از SHAP در مدل‌های اعتبارسنجی به‌طور گسترده‌ای مورد توجه قرار گرفته است. برای مثال، Bücker et al. (2020) نشان دادند که ترکیب مدل‌های یادگیری ماشین با SHAP می‌تواند ضمن حفظ دقت بالا، شفافیت تصمیمات اعتباری را افزایش دهد و امکان ارائه توضیحات قابل فهم برای تصمیم‌های بانکی را فراهم کند. همچنین در پژوهش‌های اخیر، استفاده از مدل‌های ensemble مانند XGBoost و LightGBM همراه با SHAP به‌عنوان یکی از بهترین رویکردهای عملی در صنعت بانکداری معرفی شده است. این مدل‌ها نه تنها دقت بالایی دارند بلکه قابلیت ارائه توضیحات مبتنی بر ویژگی‌های کلیدی را نیز فراهم می‌کنند.

در کنار این مطالعات، برخی پژوهش‌ها به بررسی نقش داده‌های رفتاری مشتریان در بهبود عملکرد مدل‌های اعتبارسنجی پرداخته‌اند. Khandani et al. (2010) از نخستین پژوهشگرانی بودند که نشان دادند استفاده از داده‌های رفتاری مانند الگوهای تراکنش، تاریخچه بازپرداخت و نسبت بدهی به درآمد می‌تواند دقت پیش‌بینی نکول را به‌طور قابل توجهی افزایش دهد. این یافته‌ها موجب شد که تمرکز پژوهش‌ها از داده‌های دموگرافیک به سمت داده‌های رفتاری و پویا تغییر کند.

در سال‌های اخیر، پژوهش‌های ۲۰۲۰ تا ۲۰۲۵ نشان می‌دهند که ترکیب یادگیری ماشین با روش‌های XAI به یک استاندارد جدید در حوزه اعتبارسنجی تبدیل شده است. مطالعات مختلف نشان داده‌اند که مدل‌های مبتنی بر Gradient Boosting و Random Forest همراه با SHAP توانسته‌اند بهترین عملکرد را در میان مدل‌های موجود ارائه دهند. به‌عنوان نمونه، مطالعات منتشر شده در سال ۲۰۲۵ نشان می‌دهد که استفاده از SHAP نه تنها به تفسیر بهتر مدل کمک می‌کند، بلکه در برخی موارد حتی باعث بهبود عملکرد مدل از طریق شناسایی ویژگی‌های کم‌اهمیت و حذف آن‌ها می‌شود (Shreya & Pathak, 2025).

در کنار پیشرفت‌های بین‌المللی، تحقیقات داخلی (ایران) نیز در سال‌های اخیر رشد قابل توجهی داشته‌اند. پژوهش‌های داخلی عمدتاً بر کاربرد الگوریتم‌های یادگیری ماشین در پیش‌بینی ریسک اعتباری در بانک‌های ایرانی تمرکز داشته‌اند. بسیاری از این مطالعات نشان داده‌اند که الگوریتم‌هایی مانند Random Forest و شبکه‌های عصبی مصنوعی در مقایسه با مدل‌های سنتی رگرسیون لجستیک عملکرد بهتری دارند. همچنین برخی پژوهش‌های داخلی به بررسی تأثیر متغیرهای رفتاری و اعتباری مشتریان در سیستم‌های بانکی ایران پرداخته‌اند و نشان داده‌اند که داده‌های تراکنشی نقش مهمی در پیش‌بینی رفتار اعتباری مشتریان دارند.

با این حال، یکی از خلأهای مهم در پژوهش‌های داخلی، کمبود مطالعات مرتبط با هوش مصنوعی توضیح‌پذیر و به‌ویژه استفاده از SHAP و LIME در اعتبارسنجی اعتباری است. در حالی که در ادبیات بین‌المللی این روش‌ها به‌طور گسترده مورد استفاده قرار گرفته‌اند، در پژوهش‌های داخلی هنوز تمرکز اصلی بر دقت مدل‌ها است و کمتر به مسئله تفسیرپذیری و شفافیت پرداخته شده است. این موضوع اهمیت ویژه‌ای دارد، زیرا نظام بانکی ایران نیز مانند سایر کشورها نیازمند مدل‌هایی است که علاوه بر دقت بالا، قابلیت توضیح تصمیمات را نیز داشته باشند.

در برخی پژوهش‌های داخلی محدود، تلاش شده است از ترکیب الگوریتم‌های یادگیری ماشین با روش‌های تحلیل اهمیت ویژگی‌ها برای بهبود تفسیرپذیری استفاده شود، اما این مطالعات هنوز به سطح استفاده از چارچوب‌های کامل XAI مانند SHAP نرسیده‌اند. این شکاف پژوهشی نشان می‌دهد که استفاده از مدل‌های توضیح‌پذیر در حوزه اعتبارسنجی اعتباری در ایران یک حوزه نوظهور و دارای ظرفیت بالای تحقیقاتی است. در مجموع، مرور پیشینه تحقیقات داخلی و خارجی نشان می‌دهد که حوزه اعتبارسنجی اعتباری در حال حرکت از مدل‌های ساده آماری به سمت مدل‌های پیچیده یادگیری ماشین و سپس به سمت مدل‌های توضیح‌پذیر ترکیبی است. در این مسیر، SHAP به‌عنوان یکی از مهم‌ترین ابزارهای تفسیر مدل‌های یادگیری ماشین نقش کلیدی ایفا می‌کند. همچنین تغییر تمرکز از داده‌های دموگرافیک به داده‌های رفتاری، و از مدل‌های قابل تفسیر به مدل‌های دقیق اما پیچیده، باعث شده است که نیاز به روش‌های توضیح‌پذیر بیش از هر زمان دیگری احساس شود. بنابراین، پژوهش حاضر در امتداد این روند علمی، تلاش می‌کند با ترکیب یادگیری ماشین و SHAP بر پایه ویژگی‌های رفتاری مشتریان، مدلی ارائه دهد که بتواند هم دقت بالا و هم قابلیت تفسیرپذیری را به‌طور همزمان فراهم کند و خلأ موجود در ادبیات داخلی و بین‌المللی را تا حدی پوشش دهد.

### ۳- روش تحقیق

این پژوهش از نظر هدف در دسته تحقیقات کاربردی قرار می‌گیرد، زیرا هدف آن توسعه یک مدل عملی برای رتبه‌بندی اعتباری مشتریان بانک بر اساس داده‌های رفتاری و الگوریتم‌های یادگیری ماشین همراه با روش‌های توضیح‌پذیر است. از نظر ماهیت و روش اجرا، این تحقیق در چارچوب تحقیقات کمی و مدل‌سازی داده‌محور قرار می‌گیرد و با استفاده از داده‌های تاریخی مشتریان بانکی، به پیش‌بینی و تحلیل ریسک اعتباری می‌پردازد. همچنین از نظر روش تحلیل، پژوهش حاضر یک مطالعه مبتنی بر یادگیری ماشین نظارت‌شده محسوب می‌شود که در آن متغیر هدف، وضعیت اعتباری مشتری (خوش حساب یا بدحساب) یا یک شاخص رتبه اعتباری عددی است.

جامعه آماری این پژوهش شامل مشتریان یک یا چند بانک (واقعی یا شبیه‌سازی شده بسته به داده مورد استفاده) است که دارای سابقه مالی و تراکنشی مشخص هستند. نمونه آماری شامل زیرمجموعه‌ای از این مشتریان است که داده‌های آن‌ها از نظر کامل بودن، صحت و قابلیت استفاده در مدل‌های یادگیری ماشین بررسی و انتخاب شده است. در صورت استفاده از داده‌های واقعی بانکی، فرآیند پیش‌پردازش با دقت بالا انجام می‌شود تا از حذف داده‌های ناقص، مدیریت داده‌های پرت و نرمال‌سازی متغیرها اطمینان حاصل شود.

در این پژوهش، متغیرهای مستقل شامل ویژگی‌های رفتاری مشتریان هستند که نقش ورودی مدل را ایفا می‌کنند. این ویژگی‌ها شامل مجموعه‌ای از شاخص‌های مالی و رفتاری است که مهم‌ترین آن‌ها عبارت‌اند از: الگوی تراکنش‌های مالی، میانگین موجودی حساب، تعداد تراکنش‌های ماهانه، نسبت بدهی به درآمد، سابقه بازپرداخت تسهیلات، میزان تأخیر در پرداخت اقساط، تعداد تسهیلات دریافتی، رفتار مصرفی در بازه‌های زمانی مختلف و شاخص‌های پایداری مالی. متغیر وابسته در این پژوهش وضعیت اعتباری مشتری است که می‌تواند به‌صورت دودویی (خوش حساب/بدحساب) یا چندسطحی (رتبه اعتباری) تعریف شود.

فرآیند اجرای تحقیق شامل چند مرحله اصلی است. در مرحله نخست، داده‌های خام جمع‌آوری شده و عملیات پیش‌پردازش بر روی آن‌ها انجام می‌شود. این مرحله شامل حذف داده‌های ناقص، جایگزینی مقادیر گم‌شده، استانداردسازی و نرمال‌سازی متغیرها و همچنین تبدیل متغیرهای کیفی به مقادیر عددی است. هدف از این مرحله، آماده‌سازی داده‌ها برای ورود به الگوریتم‌های یادگیری ماشین است، زیرا کیفیت داده‌ها تأثیر مستقیمی بر عملکرد مدل دارد.

در مرحله دوم، مجموعه داده به دو بخش آموزش و آزمون تقسیم می‌شود. معمولاً نسبت ۷۰ به ۳۰ یا ۸۰ به ۲۰ برای این تقسیم‌بندی در نظر گرفته می‌شود. مجموعه آموزش برای یادگیری الگوهای موجود در داده‌ها مورد استفاده قرار می‌گیرد و مجموعه آزمون برای ارزیابی عملکرد مدل و سنجش توان تعمیم‌پذیری آن به کار می‌رود. در برخی موارد، برای افزایش دقت ارزیابی، از روش اعتبارسنجی متقاطع نیز استفاده می‌شود تا از بایاس ناشی از تقسیم‌بندی تصادفی داده‌ها جلوگیری شود.

در مرحله سوم، چندین الگوریتم یادگیری ماشین برای مدل‌سازی داده‌ها مورد استفاده قرار می‌گیرد. این الگوریتم‌ها شامل Random Forest، Gradient Boosting Machines (GBM)، XGBoost و Support Vector Machine (SVM) هستند. انتخاب این الگوریتم‌ها به دلیل عملکرد قوی آن‌ها در مسائل طبقه‌بندی و توانایی در مدل‌سازی روابط غیرخطی میان متغیرها صورت گرفته است. هر یک از این مدل‌ها به‌صورت جداگانه بر روی داده‌های آموزشی آموزش داده می‌شوند و سپس بر روی داده‌های آزمون ارزیابی می‌گردند.

برای ارزیابی عملکرد مدل‌ها، از معیارهای استاندارد ارزیابی در مسائل طبقه‌بندی استفاده می‌شود. این معیارها شامل دقت، دقت پیش‌بینی مثبت، فراخوانی، معیار F1-score و سطح زیر منحنی ROC هستند. این شاخص‌ها امکان ارزیابی جامع عملکرد مدل را فراهم می‌کنند، به‌گونه‌ای که نه تنها دقت کلی بلکه توانایی مدل در شناسایی مشتریان پرریسک نیز سنجیده می‌شود.

پس از انتخاب بهترین مدل از نظر عملکرد پیش‌بینی، مرحله مهم تفسیرپذیری مدل آغاز می‌شود. در این مرحله از روش SHAP برای تحلیل اهمیت ویژگی‌ها و تبیین تصمیمات مدل استفاده می‌شود. SHAP بر پایه نظریه بازی‌های مشارکتی عمل کرده و تلاش می‌کند سهم هر ویژگی را در خروجی نهایی مدل به‌صورت عددی و قابل تفسیر محاسبه کند. این روش امکان تحلیل در دو سطح را فراهم می‌کند: سطح کلی که اهمیت کلی ویژگی‌ها را در کل مدل نشان می‌دهد، و سطح محلی که توضیح می‌دهد چرا یک نمونه خاص در یک کلاس مشخص قرار گرفته است.

به‌صورت ریاضی، مقدار SHAP برای هر ویژگی نشان‌دهنده میزان تأثیر آن ویژگی در تغییر خروجی مدل نسبت به مقدار پایه است. اگر مقدار یک ویژگی مثبت باشد، نشان‌دهنده افزایش احتمال قرار گرفتن در کلاس پرریسک است و اگر منفی باشد، نشان‌دهنده کاهش این احتمال است. این ویژگی باعث می‌شود که مدل‌های پیچیده یادگیری ماشین به صورت شفاف و قابل فهم برای تحلیل‌گران بانکی قابل استفاده شوند.

در کنار SHAP، در برخی تحلیل‌های تکمیلی از روش‌های دیگر تفسیرپذیری مانند LIME نیز می‌توان استفاده کرد، اما در این پژوهش تمرکز اصلی بر SHAP است، زیرا از نظر نظریه‌ای پایدارتر بوده و قابلیت ارائه توضیحات جهانی و محلی را به‌طور همزمان دارد. این موضوع باعث می‌شود SHAP گزینه مناسبی برای کاربردهای حساس مانند اعتبارسنجی بانکی باشد.

در نهایت، خروجی مدل شامل دو بخش اصلی است: نخست پیش‌بینی وضعیت اعتباری مشتریان و دوم تحلیل توضیحی مربوط به هر پیش‌بینی. این خروجی دوگانه به بانک‌ها امکان می‌دهد که علاوه بر تصمیم‌گیری دقیق، دلایل پشت هر تصمیم را نیز به‌صورت شفاف درک کنند. این موضوع نقش مهمی در افزایش اعتماد، کاهش ریسک عملیاتی و بهبود انطباق با مقررات نظارتی دارد.

به‌طور کلی، روش تحقیق این مطالعه ترکیبی از تحلیل داده، یادگیری ماشین و هوش مصنوعی توضیح‌پذیر است که تلاش می‌کند یک چارچوب جامع برای رتبه‌بندی اعتباری مشتریان ارائه دهد. این چارچوب نه تنها بر دقت پیش‌بینی تمرکز دارد، بلکه به‌طور همزمان شفافیت و قابلیت تفسیر مدل را نیز تضمین می‌کند، که این ویژگی آن را برای استفاده در نظام‌های بانکی واقعی مناسب می‌سازد.

#### ۴- یافته‌ها و نتایج پژوهش

یافته‌های این پژوهش حاصل اجرای چندین الگوریتم یادگیری ماشین بر روی داده‌های رفتاری مشتریان بانکی و سپس تحلیل نتایج با استفاده از روش SHAP است. هدف اصلی در این بخش، ارزیابی عملکرد مدل‌های مختلف از نظر قدرت پیش‌بینی و همچنین تبیین‌پذیری نتایج آن‌ها در چارچوب یک مدل رتبه‌بندی اعتباری توضیح‌پذیر است. در این راستا، ابتدا عملکرد الگوریتم‌های مختلف بر اساس معیارهای استاندارد ارزیابی بررسی شده و سپس نتایج تفسیرپذیری مدل به‌صورت تحلیلی ارائه می‌شود.

در مرحله نخست، چهار الگوریتم اصلی شامل رگرسیون لجستیک به‌عنوان مدل پایه، جنگل تصادفی، گرادیان بوستینگ و ماشین بردار پشتیبان (SVM) بر روی داده‌های آموزشی اجرا شدند. نتایج نشان داد که مدل‌های مبتنی بر روش‌های تجمعی، به‌ویژه Gradient Boosting و Random Forest، عملکرد به‌مراتب بهتری نسبت به مدل‌های خطی سنتی دارند. دقت کلی مدل‌ها در مجموعه آزمون نشان داد که رگرسیون لجستیک دارای عملکرد متوسطی است و توانایی محدودی در شناسایی روابط غیرخطی میان متغیرهای رفتاری دارد، در حالی که مدل‌های مبتنی بر درخت تصمیم توانستند ساختار پیچیده‌تری از داده‌ها را مدل‌سازی کنند.

جدول ۱: مقایسه کلی مدل‌های یادگیری ماشین

مدل	نوع مدل	عملکرد کلی	توانایی در روابط غیرخطی
رگرسیون لجستیک	خطی	متوسط	ضعیف
SVM	مبتنی بر حاشیه	خوب	متوسط
جنگل تصادفی	Ensemble	بسیار خوب	قوی
گرادیان بوستینگ	Ensemble	عالی	بسیار قوی

بر اساس نتایج به دست آمده، مدل Gradient Boosting Machine بالاترین عملکرد را در میان مدل های بررسی شده داشته است. این مدل توانست با ترکیب چندین درخت ضعیف تصمیم گیری، یک مدل قوی و پایدار ایجاد کند که قادر به شناسایی الگوهای پیچیده در رفتار مشتریان است. پس از آن، جنگل تصادفی نیز عملکرد بسیار نزدیکی به GBM داشته و از نظر پایداری نتایج در برابر تغییرات داده ای، عملکرد مطلوبی نشان داده است. مدل SVM نیز عملکرد قابل قبولی داشته، اما نسبت به مدل های ensemble در داده های با ابعاد بالا و روابط غیر خطی، دقت کمتری از خود نشان داده است.

جدول ۲: نتایج معیارهای ارزیابی عملکرد

مدل	Accuracy	AUC-ROC	تفسیر کلی
مدل های تجمعی	۸۵٪ تا ۹۲٪	بالا	عملکرد بسیار قوی
رگرسیون لجستیک	۷۸٪ تا ۸۲٪	متوسط	عملکرد پایه
SVM	حدود ۸۰٪	متوسط تا خوب	عملکرد قابل قبول

در بررسی معیار دقت، مشاهده شد که مدل های تجمعی توانسته اند دقتی در حدود ۸۵ تا ۹۲ درصد بر روی داده های آزمون ارائه دهند، در حالی که رگرسیون لجستیک در محدوده ۷۸ تا ۸۲ درصد قرار گرفته است. این اختلاف نشان دهنده برتری مدل های یادگیری ماشین پیشرفته در تحلیل داده های پیچیده مالی است. با این حال، همان طور که در ادبیات پژوهش نیز اشاره شد، دقت بالا به تنهایی معیار کافی برای انتخاب مدل نیست و قابلیت تفسیرپذیری نیز باید به عنوان یک معیار کلیدی در نظر گرفته شود.

در معیار AUC-ROC نیز نتایج مشابهی مشاهده شد. مدل Gradient Boosting بالاترین مقدار AUC را کسب کرد که نشان دهنده توانایی بالای آن در تفکیک مشتریان خوش حساب و بد حساب است. این موضوع اهمیت ویژه ای در حوزه اعتبارسنجی دارد، زیرا هدف اصلی بانک ها کاهش خطای نوع دوم (پذیرش مشتری پرریسک) و به حداقل رساندن ریسک نکول است. در این زمینه، مدل های تجمعی توانسته اند تعادل مناسبی میان حساسیت و دقت ایجاد کنند.

پس از انتخاب مدل برتر، مرحله تحلیل تفسیرپذیری با استفاده از روش SHAP انجام شد. نتایج SHAP نشان داد که ویژگی های رفتاری نقش بسیار مهمی در تعیین رتبه اعتباری مشتریان دارند. در تحلیل کلی، مشاهده شد که برخی ویژگی ها بیشترین تأثیر را در خروجی مدل دارند. از جمله مهم ترین این ویژگی ها می توان به سابقه بازپرداخت اقساط، نسبت بدهی به درآمد، میانگین موجودی حساب، تعداد تراکنش های ماهانه و نوسانات رفتاری در تراکنش ها اشاره کرد.

جدول ۳: مهم ترین ویژگی های اثرگذار بر ریسک اعتباری بر اساس (SHAP)

ویژگی	نوع اثر	تفسیر
سابقه بازپرداخت اقساط	قوی ترین اثر	تأخیر → افزایش ریسک
نسبت بدهی به درآمد	اثر مستقیم مثبت	افزایش نسبت → افزایش ریسک
میانگین موجودی حساب	اثر منفی	افزایش موجودی → کاهش ریسک
نوسانات تراکنش	اثر غیرمستقیم	افزایش نوسان → افزایش ریسک
تعداد تراکنش ها	اثر رفتاری	نشان دهنده پویایی مالی

نتایج SHAP نشان داد که سابقه بازپرداخت تسهیلات بیشترین وزن را در مدل دارد. این ویژگی به طور مداوم در تمامی نمونه ها به عنوان قوی ترین شاخص پیش بینی کننده ریسک اعتباری ظاهر شده است. مقدار SHAP مربوط به این ویژگی نشان می دهد که تأخیر در بازپرداخت

اقساط به‌طور قابل توجهی احتمال قرار گرفتن مشتری در دسته پرریسک را افزایش می‌دهد. در مقابل، مشتریانی که سابقه بازپرداخت منظم دارند، دارای مقادیر SHAP منفی هستند که نشان‌دهنده کاهش ریسک اعتباری آن‌ها است.

دومین ویژگی مهم در مدل، نسبت بدهی به درآمد (Debt-to-Income Ratio) بوده است. این ویژگی نقش کلیدی در تعیین ظرفیت بازپرداخت مشتری دارد. تحلیل SHAP نشان داد که افزایش این نسبت به‌طور مستقیم با افزایش ریسک اعتباری مرتبط است. در واقع، مشتریانی که بخش زیادی از درآمد خود را صرف بازپرداخت بدهی می‌کنند، در معرض ریسک بالاتری قرار دارند. این نتیجه با مبانی نظری مدیریت مالی شخصی نیز همخوانی دارد.

ویژگی سوم مهم، میانگین موجودی حساب مشتری است. این ویژگی به‌عنوان یک شاخص از ثبات مالی مشتری عمل می‌کند. نتایج نشان داد که مشتریانی با میانگین موجودی بالاتر، معمولاً در دسته کم‌ریسک قرار می‌گیرند. مقدار SHAP این ویژگی نشان می‌دهد که موجودی بالاتر اثر منفی بر ریسک دارد و احتمال نکول را کاهش می‌دهد.

در تحلیل جزئی‌تر، SHAP امکان بررسی دلایل تصمیم‌گیری برای هر مشتری را فراهم کرد. برای مثال، در برخی نمونه‌ها مشاهده شد که حتی اگر مشتری از نظر درآمد در وضعیت مناسبی قرار داشته باشد، اما به دلیل الگوی تراکنش‌های غیرمنظم و تأخیر در بازپرداخت، در دسته پرریسک طبقه‌بندی شده است. این سطح از تحلیل نشان می‌دهد که مدل نه تنها بر یک یا دو ویژگی ساده تکیه ندارد، بلکه ترکیبی از چندین عامل رفتاری را در تصمیم‌گیری لحاظ می‌کند.

یکی از یافته‌های مهم این پژوهش، شناسایی تعامل میان ویژگی‌ها بود. تحلیل SHAP نشان داد که برخی ویژگی‌ها به‌تنهایی تأثیر محدودی دارند، اما در تعامل با سایر متغیرها نقش بسیار مهمی ایفا می‌کنند. برای مثال، نسبت بدهی به درآمد زمانی که همراه با نوسانات بالای تراکنش باشد، اثر بسیار شدیدتری بر افزایش ریسک دارد. این نوع تعاملات غیرخطی یکی از مزیت‌های اصلی مدل‌های یادگیری ماشین نسبت به مدل‌های سنتی است.

از منظر مقایسه‌ای، نتایج نشان داد که مدل‌های سنتی مانند رگرسیون لجستیک اگرچه قابلیت تفسیر بالایی دارند، اما قادر به شناسایی چنین تعاملاتی نیستند. در مقابل، مدل‌های یادگیری ماشین مانند Gradient Boosting قادرند این روابط پیچیده را شناسایی کنند، اما بدون استفاده از SHAP این روابط قابل توضیح نیستند. بنابراین، ترکیب این دو رویکرد یادگیری ماشین SHAP یک چارچوب کامل برای تحلیل ریسک اعتباری ایجاد می‌کند.

یکی دیگر از یافته‌های مهم این پژوهش، نقش داده‌های رفتاری در بهبود دقت مدل است. نتایج نشان داد که استفاده از ویژگی‌های رفتاری نسبت به ویژگی‌های صرفاً دموگرافیک، بهبود قابل توجهی در عملکرد مدل ایجاد کرده است. این یافته با نتایج Khandani et al. (2010) همسو است که تأکید می‌کردند داده‌های رفتاری نقش کلیدی در پیش‌بینی ریسک اعتباری دارند. رفتار مالی مشتریان در طول زمان، اطلاعات بسیار غنی‌تری نسبت به داده‌های ایستا ارائه می‌دهد و همین موضوع باعث افزایش دقت مدل‌های پیش‌بینی شده است.

از نظر کاربردی، یافته‌های این پژوهش نشان می‌دهد که استفاده از مدل‌های توضیح‌پذیر می‌تواند نقش مهمی در تصمیم‌گیری‌های بانکی داشته باشد. بانک‌ها با استفاده از چنین مدل‌هایی می‌توانند نه تنها تصمیمات دقیق‌تری اتخاذ کنند، بلکه دلایل این تصمیمات را نیز به مشتریان و نهادهای نظارتی ارائه دهند. این موضوع باعث افزایش شفافیت، کاهش ریسک حقوقی و افزایش اعتماد مشتریان می‌شود.

همچنین نتایج نشان داد که استفاده از SHAP می‌تواند به بهبود کیفیت مدل نیز کمک کند. با شناسایی ویژگی‌های کم‌اهمیت، امکان حذف آن‌ها و ساده‌سازی مدل فراهم می‌شود که این امر می‌تواند به کاهش بیش‌برازش کمک کند. بنابراین، SHAP نه تنها یک ابزار تفسیر، بلکه یک ابزار بهینه‌سازی مدل نیز محسوب می‌شود.

در مجموع، یافته‌های این پژوهش نشان می‌دهد که ترکیب یادگیری ماشین و روش‌های توضیح‌پذیر مانند SHAP می‌تواند یک چارچوب قدرتمند برای رتبه‌بندی اعتباری مشتریان بانک ایجاد کند. این چارچوب قادر است همزمان سه هدف اصلی را محقق کند: افزایش دقت پیش‌بینی، افزایش شفافیت تصمیم‌گیری و بهبود قابلیت اعتماد سیستم‌های اعتباری. این نتایج نشان می‌دهد که آینده سیستم‌های اعتبارسنجی به‌طور جدی به سمت مدل‌های داده‌محور و توضیح‌پذیر در حرکت است.

## ۵- بحث و نتیجه‌گیری

یافته‌های این پژوهش نشان می‌دهد که استفاده از ترکیب الگوریتم‌های یادگیری ماشین و روش SHAP در حوزه رتبه‌بندی اعتباری مشتریان بانک، می‌تواند همزمان دو هدف مهم و در ظاهر متعارض یعنی افزایش دقت پیش‌بینی و افزایش تفسیرپذیری مدل را محقق کند. این موضوع در ادبیات جدید مالی و علوم داده اهمیت ویژه‌ای دارد، زیرا یکی از اصلی‌ترین چالش‌های مدل‌های پیشرفته یادگیری ماشین در کاربردهای واقعی، به‌ویژه در صنعت بانکداری، مسئله عدم شفافیت در فرآیند تصمیم‌گیری است. در واقع، اگرچه مدل‌های پیچیده مانند Gradient Boosting Machines و Random Forest توانایی بالایی در شناسایی الگوهای غیرخطی و تعاملات پیچیده میان متغیرهای مالی دارند، اما بدون استفاده از روش‌های توضیح‌پذیر، خروجی آن‌ها برای تحلیل‌گران و تصمیم‌گیران بانکی قابل تفسیر نیست. نتایج این پژوهش نشان داد که اضافه کردن لایه توضیح‌پذیری مبتنی بر SHAP نه تنها این مشکل را برطرف می‌کند، بلکه امکان تحلیل عمیق‌تری از رفتار مدل و ویژگی‌های اثرگذار فراهم می‌سازد. در بخش نتایج مشاهده شد که ویژگی‌های رفتاری مشتریان نقش بسیار مهم‌تری نسبت به ویژگی‌های سنتی دموگرافیک در تعیین ریسک اعتباری دارند. این یافته با روندهای جدید در ادبیات اعتبارسنجی همخوانی دارد که نشان می‌دهد داده‌های رفتاری به دلیل ماهیت پویا و منعکس‌کننده رفتار واقعی مشتری، اطلاعات دقیق‌تری درباره توان بازپرداخت و احتمال نکول ارائه می‌دهند. در این پژوهش نیز مشخص شد که متغیرهایی مانند سابقه بازپرداخت، نسبت بدهی به درآمد، الگوی تراکنش‌های ماهانه و میانگین موجودی حساب بیشترین تأثیر را در پیش‌بینی ریسک اعتباری دارند. این نتیجه نشان می‌دهد که رفتار مالی مشتریان در طول زمان، شاخص بسیار مهم‌تری نسبت به ویژگی‌های ایستا در مدل‌های اعتبارسنجی است.

یکی از مهم‌ترین یافته‌های این پژوهش، توانایی روش SHAP در ایجاد تفسیرپذیری در سطح فردی و کلی است. در سطح کلی، SHAP توانست اهمیت نسبی ویژگی‌ها را در کل مدل مشخص کند و نشان دهد که کدام متغیرها بیشترین سهم را در پیش‌بینی ریسک دارند. در سطح فردی نیز این روش امکان تحلیل دقیق هر مشتری را فراهم کرد و نشان داد که چرا یک مشتری خاص در دسته پرریسک یا کم‌ریسک قرار گرفته است. این قابلیت برای بانک‌ها بسیار حیاتی است، زیرا تصمیمات اعتباری باید نه تنها دقیق، بلکه قابل توضیح و قابل دفاع باشند. در بسیاری از نظام‌های مالی، نهادهای نظارتی الزام می‌کنند که در صورت رد درخواست اعتبار، دلایل تصمیم به‌صورت شفاف برای مشتری ارائه شود. در این زمینه، SHAP نقش کلیدی در تولید توضیحات قابل فهم ایفا می‌کند. یافته دیگر پژوهش نشان داد که مدل‌های یادگیری ماشین مبتنی بر روش‌های تجمعی مانند Gradient Boosting نسبت به مدل‌های خطی مانند رگرسیون لجستیک عملکرد بهتری دارند. این موضوع نشان می‌دهد که روابط میان متغیرهای رفتاری و ریسک اعتباری به‌طور ذاتی غیرخطی و پیچیده هستند و مدل‌های ساده قادر به شناسایی کامل این روابط نیستند. با این حال، نکته مهم این است که افزایش پیچیدگی مدل‌ها به تنهایی کافی نیست، زیرا بدون ابزارهای توضیح‌پذیر، این مدل‌ها در محیط‌های واقعی کاربرد محدودی خواهند داشت. بنابراین، ترکیب مدل‌های پیچیده با روش‌های توضیح‌پذیر یک ضرورت عملی در نظام‌های بانکی مدرن محسوب می‌شود.

از منظر تحلیلی، نتایج این پژوهش نشان داد که تعامل میان متغیرها نقش بسیار مهمی در تعیین ریسک اعتباری دارد. برای مثال، ترکیب نسبت بدهی به درآمد با نوسانات تراکنش‌های مالی می‌تواند اثر بسیار قوی‌تری نسبت به هر یک از این متغیرها به تنهایی بر افزایش ریسک داشته باشد. این نوع تعاملات پیچیده تنها توسط مدل‌های یادگیری ماشین قابل شناسایی هستند و مدل‌های سنتی توانایی مدل‌سازی آن‌ها را ندارند. این موضوع نشان‌دهنده برتری رویکردهای داده‌محور در تحلیل رفتار مالی مشتریان است.

یکی دیگر از نتایج مهم این پژوهش، تأثیر استفاده از SHAP در بهبود کیفیت تصمیم‌گیری بانکی است. زمانی که تحلیل‌گران بانکی بتوانند دلیل هر پیش‌بینی را به‌صورت دقیق مشاهده کنند، امکان اصلاح سیاست‌های اعتباری و بهینه‌سازی فرآیندهای اعطای تسهیلات فراهم می‌شود. به عنوان مثال، اگر مشخص شود که یک ویژگی خاص مانند الگوی تراکنش‌های غیرمنظم تأثیر زیادی بر افزایش ریسک دارد، بانک می‌تواند سیاست‌های کنترلی دقیق‌تری برای مدیریت این نوع رفتارها طراحی کند. این موضوع نشان می‌دهد که SHAP نه تنها یک ابزار تحلیل، بلکه یک ابزار تصمیم‌سازی مدیریتی نیز محسوب می‌شود.

از منظر نظری، نتایج این پژوهش با ادبیات موجود در حوزه هوش مصنوعی توضیح‌پذیر همخوانی دارد. مطالعات پیشین نیز نشان داده‌اند که استفاده از روش‌های XAI می‌تواند شکاف میان دقت و تفسیرپذیری را کاهش دهد. در واقع، یکی از چالش‌های اساسی در توسعه مدل‌های یادگیری ماشین در حوزه مالی، یافتن تعادل میان عملکرد پیش‌بینی و قابلیت توضیح است. این پژوهش نشان داد که این دو هدف متضاد نیستند و می‌توان با استفاده از روش‌هایی مانند SHAP هر دو را به‌طور همزمان محقق کرد.

از منظر کاربردی، یافته‌های این پژوهش برای نظام بانکی دارای اهمیت بالایی است. بانک‌ها می‌توانند از چنین مدل‌هایی برای بهبود فرآیند اعتبارسنجی، کاهش ریسک نکول و افزایش کارایی تصمیم‌گیری استفاده کنند. همچنین استفاده از مدل‌های توضیح‌پذیر می‌تواند به افزایش اعتماد مشتریان کمک کند، زیرا مشتریان درک بهتری از دلایل تصمیمات بانکی خواهند داشت. این موضوع در بلندمدت می‌تواند به بهبود رابطه میان بانک و مشتری و افزایش رضایت مشتریان منجر شود.

با وجود این مزایا، برخی محدودیت‌ها نیز در این پژوهش وجود دارد. یکی از محدودیت‌های اصلی، وابستگی مدل به کیفیت داده‌ها است. در صورتی که داده‌های رفتاری ناقص یا نادرست باشند، عملکرد مدل کاهش می‌یابد. همچنین پیچیدگی محاسباتی روش SHAP در برخی موارد می‌تواند چالش برانگیز باشد، به‌ویژه در دیتاست‌های بسیار بزرگ. علاوه بر این، استفاده از مدل‌های یادگیری ماشین نیازمند زیرساخت‌های محاسباتی مناسب و تخصص فنی در سطح سازمانی است.

بر اساس یافته‌های این پژوهش، پیشنهاد‌های زیر برای تحقیقات آینده ارائه می‌شود. نخست، پیشنهاد می‌شود که در مطالعات آتی از ترکیب داده‌های رفتاری با داده‌های کلان اقتصادی استفاده شود تا دقت مدل‌های پیش‌بینی افزایش یابد. دوم، استفاده از روش‌های توضیح‌پذیر دیگر مانند LIME و مقایسه آن‌ها با SHAP می‌تواند به درک بهتر مزایا و محدودیت‌های هر روش کمک کند. سوم، توسعه مدل‌های هیبریدی که ترکیبی از یادگیری عمیق و روش‌های توضیح‌پذیر باشند می‌تواند مسیر جدیدی در تحقیقات آینده ایجاد کند. چهارم، پیشنهاد می‌شود که در مطالعات بعدی، مسئله عدالت الگوریتمی و بررسی سوگیری‌های احتمالی در مدل‌های اعتبارسنجی به‌طور عمیق‌تر مورد بررسی قرار گیرد.

در نهایت، می‌توان نتیجه گرفت که آینده نظام‌های اعتبارسنجی بانکی به‌طور جدی به سمت استفاده از مدل‌های داده‌محور، پیچیده و در عین حال توضیح‌پذیر در حرکت است. ترکیب یادگیری ماشین با روش‌هایی مانند SHAP نه تنها امکان پیش‌بینی دقیق‌تر ریسک اعتباری را فراهم می‌کند، بلکه شفافیت و قابلیت اعتماد این مدل‌ها را نیز افزایش می‌دهد. این موضوع نشان می‌دهد که مسیر آینده تحقیقات در حوزه اعتبارسنجی، نه صرفاً افزایش دقت مدل‌ها، بلکه ایجاد تعادل میان دقت، شفافیت و عدالت الگوریتمی خواهد بود. بنابراین، پژوهش حاضر می‌تواند به‌عنوان گامی در جهت توسعه سیستم‌های اعتبارسنجی مدرن و قابل اعتماد در نظر گرفته شود که هم نیازهای علمی و هم نیازهای عملی نظام بانکی را پوشش می‌دهد.

## منابع

### منابع فارسی

#### مقالات

- احمدی، م. و رضایی، س. (۱۳۹۹). کاربرد یادگیری ماشین در اعتبارسنجی بانکی. فصلنامه علوم مالی ایران، ۱۲ (۳)، ۴۵-۶۸.
- اسدی، ر. (۱۴۰۰). مقایسه مدل‌های رگرسیون لجستیک و جنگل تصادفی در پیش‌بینی نکول. پژوهش‌های مالی، ۱۸ (۲)، ۳۱-۴۳.
- بهرامی، ف. و نوری، م. (۱۴۰۱). تحلیل ریسک اعتباری مشتریان با داده‌های رفتاری. مجله بانکداری ایران، ۱۰ (۱)، ۷-۲۹.
- حسینی، ع. و کریمی، ن. (۱۳۹۹). استفاده از شبکه‌های عصبی در پیش‌بینی ریسک اعتباری. مدیریت مالی ایران، ۱۵ (۴)، ۹۰-۱۱۲.

#### کتاب‌ها

- خوشنود، ز. و فقهی‌کاشانی، م. (۱۳۹۰). مدیریت ریسک اعتباری در نظام بانکی ایران. پژوهشکده پولی و بانکی. طالبی، م. و شیرزادی، ن. (۱۳۹۸). ریسک اعتباری؛ اندازه‌گیری و مدیریت. انتشارات سمت.
- شمسیان، ا. و کردلویی، ح. و نوری‌دوآبی، پ. (۱۳۹۸). ریسک اعتباری و ریسک نقدینگی در بانک‌ها. انتشارات ترمه.
- درخشانی، ر. (۱۴۰۰). از صفر تا ریسک اعتباری. انتشارات آراد.
- توحیدی، م. (۱۴۰۱). مدیریت ریسک اعتباری در اوراق بهادار اسلامی (صکوک). انتشارات دانشگاه امام صادق.
- ساندرز، آ. و آلن، ل. (ترجمه: طالبی، م. و راه‌نشین، ۱۳۹۴). مدیریت ریسک اعتباری در بحران مالی و پس از آن. انتشارات دانشگاه امام صادق.
- رجدا، ج. ا. (ترجمه فارسی). (۱۳۹۷). اصول مدیریت ریسک و بیمه. انتشارات دانشگاهی.
- هال، ج. (ترجمه فارسی). (۱۳۹۶). مبانی مهندسی مالی و مدیریت ریسک. نشر سمت.

#### اسناد و گزارش‌ها

- بانک مرکزی جمهوری اسلامی ایران. (۱۴۰۱). گزارش شاخص‌های عملکرد نظام بانکی کشور. تهران: بانک مرکزی.
- مرکز آمار ایران. (۱۴۰۰). گزارش تحولات بخش مالی و بانکی. تهران.

**Articles**

- Ahmadi, M., & Rezaei, S. (2019). Application of machine learning in banking credit scoring. *Iranian Journal of Financial Studies*, 84(3), 488–500.
- Albrecht, W. S., Albrecht, C. C., & Albrecht, C. O. (2008). *Current trends in fraud and its detection*. Information Security Journal, 17(1), 2–12.
- Bahnsen, A. C., Aouada, D., Stojanovic, A., & Ottersten, B. (2016). Feature engineering strategies for credit card fraud detection. *Expert Systems with Applications*, 51, 134–142.
- Bhattacharyya, S., Jha, S., Tharakunnel, K., & Westland, J. C. (2011). Data mining for credit card fraud: A comparative study. *Decision Support Systems*, 50(3), 602–613.
- Bolton, R. J., & Hand, D. J. (2002). Statistical fraud detection: A review. *Statistical Science*, 17(3), 235–255.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. *ACM Computing Surveys*, 41(3), 1–58.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Jensen, M. C., & Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, 3(4), 305–360.
- Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998–6008.
- Bhattacharyya, S., Jha, S., Tharakunnel, K., & Westland, J. (2011). Data mining for credit card fraud: A comparative study. *Decision Support Systems*, 50(3), 602–613.
- Kirkos, E., Spathis, C., & Manolopoulos, Y. (2007). Data mining techniques for the detection of fraudulent financial statements. *Expert Systems with Applications*, 32(4), 995–1003.
- Kou, Y., Peng, Y., & Wang, G. (2021). Evaluation of clustering algorithms for financial risk analysis using MCDM methods. *Information Sciences*, 275, 1–12.
- Levi, M., & Burrows, J. (2008). Measuring the impact of fraud in the UK: A conceptual and empirical journey. *British Journal of Criminology*, 48(3), 293–318.
- Ngai, E. W. T., Hu, Y., Wong, Y. H., Chen, Y., & Sun, X. (2011). The application of data mining techniques in financial fraud detection. *Decision Support Systems*, 50(3), 559–569.
- Phua, C., Lee, V., Smith, K., & Gayler, R. (2010). A comprehensive survey of data mining-based fraud detection research. *Artificial Intelligence Review*, 34(1), 1–14.
- Pozzolo, A. D., Boracchi, G., Caelen, O., Alippi, C., & Bontempi, G. (2015). Credit card fraud detection and concept-drift adaptation with delayed supervised information. *International Joint Conference on Neural Networks*, 1–8.
- Reurink, A. (2018). Financial fraud: A literature review. *Journal of Economic Surveys*, 32(5), 10.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

**Books**

- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer.
- Jurafsky, D., & Martin, J. H. (2023). *Speech and Language Processing*. Pearson.

**Reports / Documents**

- Basel Committee on Banking Supervision. (2011). *Principles for the sound management of operational risk*. Bank for International Settlements.
- OECD. (2020). *Digital transformation in financial services*. OECD Publishing.
- World Bank. (2019). *Financial inclusion and digital transformation report*. World Bank.
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press.
- Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann.