



Value-Based Allocation Strategy for Banking Facilities: Leveraging Big Data and Machine Learning to Optimize the Customer-Bank Relationship

Masoumeh Vakili¹, Seyed Ahmad Shayannia^{*2}, Maryam Rahmaty³, Reza Radfar⁴

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

2*- Department of Industrial Management, Fi.C., Islamic Azad University, Firoozkooh, Iran.

3- Department of Management, Cha.C., Islamic Azad University, Chalus, Iran.

4- Department of Industrial Management, SR.C., Islamic Azad University,
Tehran, Iran.

Abstract

In the era of smart marketing and big data, the ability of banks to accurately identify customers and optimally allocate financial resources is a key factor for increasing organizational confidence and productivity. This research focuses on designing an intelligent big data-based banking facility allocation model that aims to go beyond simply reducing risk and move towards maximizing the value of eligible customers. Using existing financial and credit records, K-Means clustering was first used to separate customers into three distinct risk-taking groups (low, medium, high risk). Then, a Random Forest model with a prediction accuracy of 96% was used to accurately assess the risk profile of each cluster. The main innovation of the research lies in the allocation stage, where a hybrid optimization method including Analytic Hierarchy Process (AHP) and Particle Swarm Algorithm (PSO) was used to optimize the loan allocation parameters. The results show that this hybrid approach not only significantly reduces credit risk, but also improves the overall efficiency of the bank by intelligently directing resources towards profitable sectors. This model provides a powerful tool for making accurate credit decisions, based on customer value, and in line with the strategic marketing goals of banks.

Keywords: Intelligent model, bank lending, big data, machine learning, analytic hierarchy process

Citation:

Vakili, M., Shayannia, S.A., Rahmaty, M. and Radfar, R. (2026). Value-Based Allocation Strategy for Banking Facilities: Leveraging Big Data and Machine Learning to Optimize the Customer-Bank Relationship. *Journal of Intelligent Marketing Management*, 7(2), 86-107.



استراتژی تخصیص ارزش محور تسهیلات بانکی: بهره‌گیری از کلان‌داده و یادگیری ماشینی

برای بهینه‌سازی رابطه مشتری-بانک

معصومه و کیلی^۱، سید احمد شایان نیا^{۲*}، مریم رحمتی^۳، رضا رادفر^۴

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

۲* - گروه مدیریت صنعتی، واحد فیروز کوه، دانشگاه آزاد اسلامی، فیروز کوه، ایران.

۳- گروه مدیریت، واحد چالوس، دانشگاه آزاد اسلامی، چالوس، ایران.

۴- گروه مدیریت صنعتی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

چکیده

در عصر بازاریابی هوشمند و کلان‌داده، توانایی بانک‌ها در شناخت دقیق مشتریان و تخصیص بهینه منابع مالی، عاملی کلیدی برای افزایش اطمینان و بهره‌وری سازمانی است. این تحقیق بر طراحی یک مدل هوشمند تخصیص تسهیلات بانکی مبتنی بر کلان‌داده متمرکز است که هدف آن فراتر از صرفاً کاهش ریسک، حرکت به سمت به حداکثر رساندن ارزش مشتریان واجد شرایط است. با استفاده از سوابق مالی و اعتباری موجود، ابتدا خوشه‌بندی K-Means برای تفکیک مشتریان به سه گروه متمایز ریسک‌پذیری (کم، متوسط، پرریسک) به کار گرفته شد. سپس، مدل جنگل تصادفی (Random Forest) با دقت پیش‌بینی ۹۶٪ برای ارزیابی دقیق پروفایل ریسک هر خوشه به کار گرفته شد. نوآوری اصلی تحقیق در مرحله تخصیص نهفته است؛ جایی که از یک روش بهینه‌سازی ترکیبی شامل تحلیل سلسله مراتبی (AHP) و الگوریتم ازدحام ذرات (PSO) استفاده شد تا پارامترهای تخصیص وام‌ها بهینه گردند. نتایج نشان می‌دهد این رویکرد ترکیبی نه تنها ریسک اعتباری را به شکل معناداری کاهش می‌دهد، بلکه با هدایت هوشمند منابع به سمت بخش‌های سودآور، بهره‌وری کلی بانک را ارتقا می‌بخشد. این مدل، ابزاری قدرتمند برای اتخاذ تصمیمات اعتباری دقیق، مبتنی بر ارزش مشتری، و در راستای اهداف بازاریابی استراتژیک بانک‌ها فراهم می‌آورد.

کلیدواژه‌ها: مدل هوشمند، اعطای تسهیلات بانکی، کلان‌داده، یادگیری ماشینی، تحلیل سلسله مراتبی

استناد:

و کیلی، معصومه و شایان نیا، سید احمد و رحمتی، مریم و رادفر، رضا. (۱۴۰۴). استراتژی تخصیص ارزش محور تسهیلات بانکی: بهره‌گیری از کلان‌داده و یادگیری ماشینی برای بهینه‌سازی رابطه مشتری-بانک. مدیریت بازاریابی هوشمند، ۷(۲)، ۸۶-۱۰۷.

تاریخ دریافت: ۱۴۰۴/۱۱/۲۵

تاریخ ویرایش: ۱۴۰۵/۰۱/۱۰

تاریخ پذیرش: ۱۴۰۵/۰۲/۰۲

تاریخ انتشار: ۱۴۰۵/۰۴/۰۱

<https://doi.org/JABM.3.2.15564.35125656565977>

نشریه مدیریت بازاریابی هوشمند، ۱۴۰۵، دوره ۷، شماره ۲، پیاپی ۳۲

ناشر: نشریه مدیریت بازاریابی هوشمند

نوع مقاله: علمی پژوهشی

© نویسندگان



مقدمه

در عصر دیجیتال و با وجود بازارهای رقابتی و راه‌های متنوع ارائه خدمت، بانک‌ها تحولات جدی و اساسی را تجربه می‌کنند. هدف اصلی، رضایت مشتری است و شناخت نیازهای مشتریان مطابق با شرایط امروز و ارائه خدمات مناسب و کیفی به آنان از دغدغه‌های همیشگی و اصلی بانکداران به شمار می‌آید. بانکداری الکترونیک به معنای الکترونیکی کردن کامل بانک‌ها و تمام فعالیت‌ها، برنامه‌ها و کارکردهای آن است. (ادی و همکاران، ۲۰۲۴) از جمله مزایای بانکداری الکترونیک می‌توان به افزایش سرعت، صرفه‌جویی در زمان، کاهش هزینه خدمات، افزایش درآمد، بالا رفتن دقت کار و امکان بیشتر انطباق با قوانین جدید اشاره کرد. در این میان، حجم بالایی از اطلاعات به منظور بررسی و تصمیم‌گیری در مورد تدوین برنامه‌ها مورد نیاز است. تجزیه و تحلیل کلان‌داده‌ها یکی از گزینه‌های استراتژیک فناوری برای سازمان‌دهی اطلاعات است (کانگ، ۲۰۲۴). فناوری‌ها با ایجاد بینش برای استراتژی‌های آینده بر اساس عملیات روزانه، به نوبه خود می‌توانند در تصمیم‌گیری مؤثر باشند و این امر می‌تواند سازمان‌ها را در دستیابی به موفقیت در عرصه رقابت کمک کند (بین، ۲۰۲۴).

تحلیل کلان داده‌ها در بانک‌ها و سازمان‌های مالی امروز نقش مهمی ایفا می‌کند. این تحلیل‌ها می‌توانند اطلاعات ارزشمندی را برای سازمان‌ها فراهم کنند و به آن‌ها در دستیابی به تصمیم‌گیری‌های هوشمندانه‌تر کمک کنند. بانک‌های بین‌المللی نیز به تدریج از قدرت داده‌ها برای کسب بینش در حوزه‌های مختلف عملکردی مانند تحلیل مشتریان، فروش محصولات، مدیریت رعایت مقررات، مدیریت ریسک اعتباری، و مقابله با جرائم مالی استفاده می‌کنند. با این وجود، بسیاری از این بانک‌ها هنوز در ساخت و پیاده‌سازی محیط کلان داده خود مردد هستند، زیرا سودمندی آن هنوز به طور کامل درک نشده است. عواملی مانند مدل کسب‌وکار، تکنولوژی و ساختار سازمانی در ایجاد این تردید نقش دارند (وانگ و همکاران، ۲۰۲۴)

بکارگیری کلان داده در صنعت بانکداری از جنبه‌های مختلف می‌تواند اهمیت بالایی داشته باشد. انطباق با مقررات جدید و چالش‌برانگیزی که از سوی مراجع ذی‌ربط وضع شده‌اند، یکی از این موارد است. همچنین، کلان داده‌ها به بانک‌ها این امکان را می‌دهند که فرآیند احراز هویت و نمایه‌سازی مشتریان را بهبود بخشند و براساس ریسک‌های موجود عمل کنند، که در نهایت منجر به افزایش تعداد مشتریان بالقوه می‌شود (شی و همکاران، ۲۰۲۴). از سوی دیگر، کلان داده‌ها با کاهش هزینه‌های عملیاتی و افزایش بهره‌وری تجاری، به بانک‌ها کمک می‌کنند. تجزیه و تحلیل داده‌های متنوع مربوط به مشتریان، به دستیابی به بینش‌های عمیق‌تر و همچنین تحلیل جریان‌های مالی ماهیانه مشتریان و بررسی رفتارهای مصرفی آن‌ها منجر می‌شود. این تحلیل‌ها می‌توانند الگوهای رفتاری مشتریان را با سایر کسب‌وکارها مقایسه کرده و مدل بانکداری شرکتی را تقویت کنند. کلان داده‌ها همچنین امکان ارائه دید ۳۶۰ درجه از رفتار مشتری، بهبود کارایی فرآیندهای داخلی و تحلیل روند بازار را فراهم می‌کنند، که همه این‌ها در راستای حفظ مشتریان فعلی و جذب مشتریان جدید مفید هستند (هونگ و همکاران، ۲۰۲۳). علاوه بر این، ارزیابی عملکرد و مقایسه با رقبا برای بهبود کارایی، ایجاد پروفایل ریسک برای تعیین امتیاز اعتباری و مدیریت ریسک مشتریان، و همچنین تعاملات هوشمندانه از طریق شناسایی اولویت‌ها و ارائه خدمات در زمان مناسب از دیگر مزایای استفاده از کلان داده در بانکداری است. در نهایت، کلان داده‌ها به مدرن‌سازی زیرساخت‌ها و استفاده از مدل‌های معماری باز برای کاهش هزینه محصولات کمک می‌کنند.

در سال‌های اخیر، فناوری مالی به عنوان یک عامل تحول‌زا در بخش مالی به سرعت توسعه یافته است. فناوری مالی به طور کامل رویکرد انجام کسب‌وکارها را بازتعریف کرده است. این فناوری به‌طور اساسی با ادغام تکنولوژی و ابزارهای مالی، راهکارهایی ارائه

می‌دهد که از نظر کارآیی بسیار مؤثرتر از روش‌های سنتی مورد استفاده در موسسات مالی هستند. هرچند فناوری مالی جایگزین سیستم بانکی سنتی نیست، اما می‌تواند به سادگی خدمات بانکی را تسهیل کند. امروزه، بسیاری از خدمات بانکی با استفاده از فناوری‌هایی مانند یادگیری ماشین، تحلیل داده‌ها، و الگوریتم‌های کلان داده به راحتی در دسترس قرار می‌گیرند. در سیستم بانکی سنتی، رویکردی یکپارچه به کسب و کار بانکی اتخاذ می‌شود که در آن عملیات اصلی مانند جذب سپرده و اعطای تسهیلات در اولویت قرار دارند، در حالی که خدماتی مانند انتقال وجه، نقطه فروش و بیمه به عنوان فعالیت‌های ثانویه در نظر گرفته می‌شوند. وام‌دهی هوشمند، از طریق پلتفرم‌های دیجیتال، امکان ارائه وام‌های کم‌هزینه و سریع را فراهم می‌کند که برای بخش وسیعی از بازار که قبلاً پوشش داده نشده بود، دسترس‌پذیر است.

وام‌دهی هوشمند به عنوان صنعتی در حال رشد در حوزه وام‌دهی دیجیتال شناخته می‌شود که هدف آن تأمین نیازهای مختلف تسهیلاتی، از جمله وام‌های مصرفی، تسهیلات برای شرکت‌های خرد و متوسط، و وام‌های سرمایه در گردش و کوتاه‌مدت است. این حوزه شامل دسته‌ای از دارایی‌ها با ریسک نسبتاً کم برای سرمایه‌گذاران خرد و سازمانی می‌شود. پلتفرم‌های وام‌دهی دیجیتال و ابزارهای پشتیبان آن‌ها، مانند سامانه‌های هوشمند امتیازدهی اعتباری و خدمات با برچسب سفید، بخشی از این صنعت در حال رشد هستند. این پلتفرم‌ها با ارائه بازدهی بیشتر نسبت به انتظارات کنونی بانک‌ها، تسهیلات‌دهندگان را به مشتریانی که به دنبال وام‌های سریع و کوتاه‌مدت هستند، متصل می‌کنند. بر این اساس، در این پژوهش تلاش خواهیم کرد تا بررسی کنیم چگونه می‌توان با استفاده از رویکرد کلان داده‌ها، محصولات اعتباری هوشمند طراحی کرد که علاوه بر داشتن ریسک پایین، با نیازهای جامعه و استراتژی‌های ذینفعان هماهنگ بوده و سوددهی مناسبی نیز داشته باشند. هدف این تحقیق نشان دادن این موضوع است که به کارگیری کلان داده‌ها و تحلیل آن‌ها می‌تواند به طور مؤثری در صنعت اعتباردهی بانکی جهت خلق محصولات اعتباری هوشمند به کار گرفته شود.

در این تحقیق تلاش می‌شود تا مدلی هوشمند برای اعطای تسهیلات بانکی ارائه شود که این مدل بر اساس کلان داده و با استفاده از الگوریتم‌های یادگیری ماشین ارائه می‌شود مدل ارائه شده دارای ویژگی‌هایی است که از نظر رویکرد با الگوهای ارائه شده متفاوت بوده و در بخش روش شناسی به آن اشاره می‌شود. ساختار مقاله حاضر به گونه‌ای است که در بخش بعدی مرور ادبیات ارائه شده، سپس روش شناسی تشریح شده و در ادامه تجزیه و تحلیل یافته‌ها و در انتها نتیجه‌گیری ارائه می‌شود.

مرور ادبیات

در این بخش به تشریح مرور ادبیات در حوزه مورد مطالعه پرداخته می‌شود مقالات معرفی شده عمدتاً مربوط به ۵ سال اخیر بوده و عموماً مبتنی بر ارائه تسهیلات بانکی و مدل‌های مرتبط و البته گاهی مدل‌های هوشمند می‌باشد. کواتنگ و همکاران^۱ (۲۰۱۹) به بررسی روابط علی بین کارایی کاربردهای فناوری اطلاعات (IT) و عملکرد بانک‌ها پرداخته‌اند. ویبسونو و همکاران^۲ (۲۰۱۹) در پژوهشی به بررسی کاربردهای داده‌های کلان و هوش مصنوعی در بانکداری مرکزی پرداخته‌اند. ایوانچنکو و همکاران^۳ (۲۰۱۹) در مقاله‌ای به بررسی نقش فناوری‌های تحلیل داده‌های بزرگ در بازاریابی بانکی پرداخته‌اند. صالح و یانچوسکی^۴ (۲۰۱۹) در پژوهشی به بررسی ملاحظات امنیتی مرتبط با انتخاب راه‌حل‌های کلان داده در یک بانک مالزیایی پرداخته‌اند. ایندریاساری و همکاران^۵ (۲۰۱۹) در مقاله‌ای

^۱ Kwateng et al

^۲ Wibisono et al

^۳ Ivanchenko et al

^۴ Salleh & Janczewski

^۵ Indriasari et al

به بررسی تحول بانکداری دیجیتال و کاربردهای هوش مصنوعی (AI) و تحلیل داده‌های کلان (BDA) در بهبود تجربه مشتری در صنعت بانکداری اندونزی پرداخته‌اند.

هونگ و همکاران^۳ (۲۰۲۰) در تحقیقی به بررسی استفاده از تجزیه و تحلیل داده‌های کلان در یک بانک تجاری در آسیا پرداختند. علی و همکاران (۲۰۲۰) به بررسی تأثیر شیوه‌های مدیریت زنجیره تأمین سبز و تجزیه و تحلیل داده‌های بزرگ بر عملکرد زیست‌محیطی و مالی بانک‌ها در کشورهای آسیه آن پرداخته‌اند. مقاله‌ای از علی و همکاران^۴ (۲۰۲۱) به بررسی تأثیر داده‌های کلان و تجزیه و تحلیل پیش‌بینی‌کننده (BDPA) بر عملکرد اجتماعی و زیست‌محیطی بانک‌های اسلامی می‌پردازد. مقاله ژو و یانگ^۵ (۲۰۲۱) به بررسی تأثیر تعهد به پایداری، مدیریت زنجیره تأمین سبز، ادغام داده‌های کلان و عملکرد منابع انسانی سبز در بانک‌ها می‌پردازد. سلطانی دلگشا و همکاران^۶ (۲۰۲۱) در مطالعه‌ای با استفاده از روش دلفی چهار مرحله‌ای، به این نتیجه رسیدند که تشخیص تقلب و تحلیل ریسک اعتباری از مهم‌ترین کاربردهای داده‌های کلان در صنعت بانکداری هستند. چنگ و فنگ^۷ (۲۰۲۱) در پژوهشی به بررسی کاربرد داده‌های کلان در صنعت بانکداری پرداخته و چهار جنبه کلیدی را تحلیل کردند:

ابراهیمی و همکاران^۸ (۲۰۲۲) در مقاله‌ای به بررسی چالش‌ها و فرصت‌های کلان داده و اینترنت اشیا در صنعت بانکداری الکترونیک پرداخته‌اند. الخطیب (۲۰۲۲) در پژوهش خود به بررسی تأثیر سرمایه فکری بر عملکرد نوآوری در بخش بانکداری اردن و نقش تعدیل‌کننده تجزیه و تحلیل داده‌های بزرگ پرداخته است. انی و همکاران (۲۰۲۲) در تحقیقی به بررسی تأثیر هوش مصنوعی و تجزیه و تحلیل داده‌های بزرگ در بازاریابی بانکی هند پرداخته‌اند. سازو و جهان (۲۰۲۲) در تحقیقی به بررسی تأثیر تجزیه و تحلیل‌های مبتنی بر بلاک چین در صنعت بانکداری پرداخته‌اند. سازو و جهان (۲۰۲۲) در پژوهشی به بررسی تأثیر تجزیه و تحلیل داده‌های کلان بر صنعت خدمات مالی، به ویژه بانک‌ها، پرداخته‌اند. ایزنبرگ و همکاران (۲۰۲۲) به بررسی تأثیر ارزیابی ریسک اعتباری بر عملکرد مالی بانک‌های تجاری در آمریکا و اروپا در بازه زمانی ۲۰۱۷ تا ۲۰۲۱ پرداخته‌اند.

رشدالحسن و همکاران (۲۰۲۳) در مطالعه‌ای به بررسی تأثیر نوآوری‌های داده بر بانکداری پرداخته‌اند. هونگ و همکاران (۲۰۲۳) در پژوهشی به چگونگی بهره‌برداری از تجزیه و تحلیل داده‌های کلان در صنعت بانکداری پرداختند. گایاپره و همکاران (۲۰۲۳) در مطالعه‌ای به بررسی بهبود خدمات بانکی در غنا با استفاده از تحلیل‌های داده‌های کلان پرداخته‌اند. الدمور و همکاران (۲۰۲۳) در مقاله‌ای به بررسی تأثیر شیوه‌های کاربردی تجزیه و تحلیل داده‌های بزرگ بر عملکرد بانک‌های تجاری در اردن پرداخته‌اند.

¹ Artificial Intelligence

² Big Data Analytics

³ Hung et al

⁴ Ali et al

⁵ big data and predictive analytics

⁶ Zhu & Yang

⁷ Soltani Delgosha et al

⁸ Cheng & Feng

⁹ Ebrahimi et all

ادی و همکاران^۱ (۲۰۲۴) در مطالعه‌ای به بررسی نقش تحلیل‌های پیش‌بینی‌کننده در مدیریت ریسک اعتباری در بانک‌ها پرداخته‌اند. چانگ و همکاران^۲ (۲۰۲۴) در تحقیقی به بررسی تأثیر فناوری‌های نوین و تجزیه و تحلیل داده‌ها بر سیستم‌های بانکداری B2B^۳ و تأمین مالی سبز پرداخته‌اند. شوستان و همکاران^۴ (۲۰۲۴) در مطالعه‌ای نشان دادند که تحلیل داده‌های کلان نقش حیاتی در کشف و پیشگیری از تقلب مالی دارد. احمدی^۵ (۲۰۲۴) در مطالعه‌ای به بررسی تأثیر فناوری‌های هوش مصنوعی و داده‌های کلان بر صنعت مالی پرداخته است. محمدی و همکاران^۶ (۲۰۲۴) به بررسی عوامل مؤثر بر استفاده از هوش تجاری و تجزیه و تحلیل در صنعت بانکداری پرداختند و تأثیر تجربه کاری کارکنان بر این استفاده را در بانک‌های تجاری اردن بررسی کردند. اولابانجی و همکاران^۷ (۲۰۲۴) در تحقیقی به بررسی تأثیر هوش مصنوعی بر مدیریت اطلاعات شناسایی شخصی در بخش مالی پرداخته‌اند. لیاو و همکاران^۸ (۲۰۲۴) در پژوهشی به بررسی تأثیر زیرساخت‌های کلان‌داده بر نوآوری فین‌تک در بانک‌ها پرداخته‌اند. لیو و همکاران^۹ (۲۰۲۴) در تحقیق خود به بررسی تأثیر استفاده از هوش مصنوعی (AI) توسط وام‌دهندگان بر کاهش تخلفات در وام‌گیرندگان که بلايای طبیعی را تجربه کرده‌اند، پرداخته‌اند. تحقیق عبدالله محقوب (۲۰۲۴) به بررسی بهینه‌سازی تاییدیه وام بانکی با استفاده از مدل‌های یادگیری عمیق و متدهای طبقه‌بندی باینری می‌پردازد. سادوک و اسدی (۲۰۲۴) در مقاله‌ای به بررسی تأثیرات هوش مصنوعی در تحلیل اعتبار بانکی پرداختند. کانگ (۲۰۲۴) در پژوهش خود با عنوان "از بین رفتن اطلاعات خصوصی با ظهور کلان داده‌ها" تأثیر کلان داده‌ها بر ارزش اطلاعات خصوصی وام‌گیرندگان را بررسی می‌کند. یین (۲۰۲۴) در مقاله خود تأثیر افزایش حجم داده‌های شرکت‌ها بر بانک‌های تجاری را بررسی می‌کند. شی و همکاران (۲۰۲۴) در مطالعه خود رویکردی نوین مبتنی بر مجموعه‌های خشن همسایگی که برای تحلیل و پردازش داده‌های نامشخص و پیچیده استفاده می‌شود، وانگ و همکاران (۲۰۲۴) به بررسی تأثیر کلان داده‌ها و وام‌های سبز بر کارایی انرژی شرکت‌ها پرداخته‌اند.

برای موضوع این تحقیق شواهد موجود در مطالعات پیشین نشان می‌دهند که ترکیب همزمان روش‌های کلان داده، یادگیری ماشین، و بهینه‌سازی تصمیم‌گیری به‌طور جامع و هماهنگ به‌ندرت مورد توجه قرار گرفته است. این شکاف‌های تحقیقاتی را می‌توان به‌طور دقیق‌تر به شرح زیر بیان کرد:

- ترکیب داده‌های کلان و الگوریتم‌های یادگیری ماشین
- مدل‌سازی پیش‌بینی ریسک و بهینه‌سازی تصمیم‌گیری
- مدل‌های چندمرحله‌ای و اعتبارسنجی جامع
- پیش‌بینی و تصمیم‌گیری در محیط‌های پویا و توسعه‌ای

با توجه به این شکاف‌ها، تحقیق در زمینه طراحی و پیاده‌سازی مدل‌های هوشمند اعطای تسهیلات بانکی که به‌طور همزمان و جامع داده‌های کلان، الگوریتم‌های یادگیری ماشین و تکنیک‌های بهینه‌سازی تصمیم‌گیری را ترکیب کنند، یک فرصت تحقیقاتی مهم و

¹ Addy et al

² Chang et al

³ business-to-business

⁴ Shoetan et al

⁵ Ahmadi

⁶ Mohammed et al

⁷ Olabanji et al

⁸ Liao et al

⁹ Liu et al

نوآورانه است. این تحقیق می‌تواند به پیشرفت علمی و عملی در حوزه اعطای تسهیلات بانکی و بهبود فرآیندهای تصمیم‌گیری کمک کند.

روش شناسی

این پژوهش با استفاده از روش تحقیق توصیفی-تحلیلی طراحی شده است و شامل مراحل کیفی و کمی به منظور تحلیل جامع اطلاعات مربوط به ریسک اعتباری مشتریان بانک‌ها می‌باشد. در ابتدا، مرحله کیفی با هدف استخراج عوامل مؤثر بر ریسک اعتباری و رفتار مالی مشتریان از طریق مصاحبه‌های عمیق با مدیران و کارشناسان عرصه بانکی انجام شد. این رویکرد به شناسایی چالش‌ها و الگوهای رفتاری کمک کرده و زمینه‌ساز تعریف دقیق‌تر مسئله پژوهش گردید.

پس، در مرحله کمی، داده‌های مرتبط از جمله تراکنش‌ها، سوابق مالی و اعتباری مشتریان، از سیستم‌های داخلی بانکی و منابع معتبر برون‌سازمانی جمع‌آوری شد. برای تجزیه و تحلیل داده‌ها، از تکنیک‌های آماری پیشرفته، از جمله تحلیل رگرسیون، خوشه‌بندی، و مدل‌های یادگیری ماشین استفاده گردید تا به شناسایی الگوهای تأثیرگذار بر وضعیت اعتباری مشتریان پرداخته شود. این مراحل به گونه‌ای طراحی شده‌اند که نتایج و شواهد مستحکمی را برای اعتبارسنجی و بهبود مدل‌های پیش‌بینی ریسک اعتباری فراهم آورند. ترکیب این دو رویکرد تحقیقی به ما این امکان را می‌دهد که به صورت جامع و دقیق به مسئله پژوهش پرداخته و نقاط قوت و ضعف مدل‌های اعتباری موجود را شناسایی کنیم. در نهایت، یافته‌های حاصل از این تحقیق می‌تواند به بهینه‌سازی تصمیم‌گیری در اعطای تسهیلات و کاهش ریسک‌های اعتباری کمک نماید.

تجزیه و تحلیل داده‌ها با استفاده از تکنیک‌های یادگیری ماشین و مدل‌سازی پیش‌بینی انجام می‌شود که شامل مراحل مشخصی از تجزیه و تحلیل ریسک و خوشه‌بندی مشتریان است. در مرحله اول، داده‌های گردآوری‌شده از منابع مختلف، شامل اطلاعات مالی و اعتباری مشتریان، تحت عملیات پیش‌پردازش داده‌ها قرار می‌گیرند. این مرحله شامل پاک‌سازی داده‌ها، تصحیح ناهنجاری‌ها و تبدیل داده‌ها به فرمتی مناسب برای تحلیل است.

پس از پیش‌پردازش، با استفاده از الگوریتم K-Means، خوشه‌بندی مشتریان انجام می‌شود تا گروه‌های متفاوتی از مشتریان با ویژگی‌های مشابه شناسایی گردند. اعتبار خوشه‌بندی و بررسی ویژگی‌های خوشه‌های اعتباری مشتریان به ما این امکان را می‌دهد که الگوهای رفتاری و ریسک‌های خاص هر گروه را تحلیل کنیم.

برای مدل‌سازی پیش‌بینی ریسک، از الگوریتم جنگل تصادفی (Random Forest) استفاده می‌شود، که به صورت جامع‌تری به تحلیل داده‌ها و شناسایی عواملی که به ریسک اعتباری مرتبط هستند، می‌پردازد. در این مرحله، پس از جمع‌آوری و پیش‌پردازش داده‌ها، داده‌ها به دو بخش آموزشی و تست تقسیم‌بندی می‌شوند. نتایج پیاده‌سازی الگوریتم جنگل تصادفی مورد تحلیل و تفسیر قرار می‌گیرد تا به طور دقیق‌تری به ارزیابی و اعتبارسنجی مدل پرداخته شود.

علاوه بر این، برای بهینه‌سازی تصمیم‌گیری در تخصیص تسهیلات بانکی، از روش تحلیل سلسله‌مراتبی (AHP) استفاده می‌شود. این روش شامل تکمیل ماتریس مقایسات زوجی با استفاده از نظر خبرگان، تعیین وزن معیارها، تحلیل وزن‌ها، و همچنین ارزیابی نسبت سازگاری (Consistency Ratio - CR) است. نتایج این تحلیل‌ها به شفاف‌سازی و بهینه‌سازی فرآیند اعطای تسهیلات کمک می‌کند.

در نهایت، الگوریتم بهینه‌سازی ازدحام ذرات (PSO) برای تعیین مقدار بهینه تسهیلات بانکی پیاده‌سازی می‌شود. اعتبارسنجی و بهبود مدل PSO از دیگر مراحل کلیدی است که به ما این امکان را می‌دهد تا به‌طور مستمر مدل بهینه‌سازی را ارتقا داده و به تصمیم‌گیری‌های هوشمندانه‌تری دست یابیم.

جامعه آماری این تحقیق شامل مشتریان بانک‌های تجاری معتبر در ایران است که به‌طور هدفمند برای بررسی عوامل مؤثر بر وضعیت اعتباری و ریسک اعتباری انتخاب شده‌اند. داده‌های جمع‌آوری شده از سیستم‌های داخلی بانکی شامل اطلاعات تراکنش‌ها، سوابق مالی، و تاریخچه بازپرداخت مشتریان، به همراه داده‌های برون‌سازمانی از جمله تحلیل رفتار مشتریان در شبکه‌های اجتماعی و سوابق اعتباری از مراجع رسمی، به‌منظور ایجاد معیارهای جامع و دقیق برای ارزیابی اعتبار، مورد استفاده قرار گرفته‌اند. این ترکیب داده‌ها می‌تواند به بهبود دقت مدل‌های پیش‌بینی ریسک اعتباری کمک کند و نمایه‌ای کاملاً جامع از وضعیت مالی و رفتاری مشتریان ارائه دهد.

جمع‌آوری داده‌ها از سیستم‌های داخلی بانکی شامل داده‌های تراکنش، سوابق مالی مشتریان، سوابق بازپرداخت و مشخصات اعتباری آن‌ها می‌شود. علاوه بر داده‌های درون‌سازمانی، داده‌های برون‌سازمانی مانند شبکه‌های اجتماعی و اطلاعات اقتصادی و اجتماعی مرتبط با مشتریان نیز می‌تواند به ارزش پیش‌بینی مدل‌های اعتباری افزوده و کمک کند تا نمایه‌ای کامل‌تر از ریسک و وضعیت اعتباری مشتری شکل بگیرد. منابع خارجی برای جمع‌آوری داده‌ها شامل:

شبکه‌های اجتماعی: تحلیل رفتار مشتریان از طریق پلتفرم‌های اجتماعی برای استخراج اطلاعات مرتبط با رفتار مالی و رضایت مشتری. سوابق اعتباری: داده‌های دریافت شده از مراجع اعتباری مانند گزارش‌های اعتباری که جزئیات بدهی‌ها و میزان بازپرداخت‌های گذشته را فراهم می‌آورند.

داده‌های کلان عمومی: اطلاعات اقتصادی، اجتماعی، و بازار نیز می‌تواند به تحلیل جامع‌تر در فرآیند اعطای تسهیلات کمک کند.

تجزیه و تحلیل داده‌ها

در این بخش، به پیاده‌سازی عملی مدل هوشمند اعطای تسهیلات پرداخته می‌شود. تعداد کل متغیرهای استفاده شده برابر با ۱۸ متغیر است که شامل ۹ متغیر درون‌سازمانی، ۵ متغیر برون‌سازمانی، و ۴ متغیر کلان عمومی می‌باشد. در ادامه، توضیح مختصری برای هر دسته از متغیرها ارائه می‌شود:

۱. متغیرهای درون‌سازمانی (۹ متغیر): این متغیرها به اطلاعات مربوط به عملکرد و فرآیندهای داخلی بانک اشاره دارند. این داده‌ها به بانک کمک می‌کنند تا ریسک‌های اعتباری را بر اساس سوابق مالی و اعتباری مشتریان تحلیل کنند.

۲. متغیرهای برون‌سازمانی (۵ متغیر): این متغیرها به عوامل خارج از کنترل بانک اشاره دارند که تأثیر قابل توجهی بر شرایط اعتباری مشتریان دارند. این داده‌ها به بانک کمک می‌کنند تا تأثیرات عوامل محیطی و اقتصادی بر عملکرد مشتریان را بهتر درک کنند.

۳. متغیرهای کلان عمومی (۴ متغیر): این متغیرها به شرایط و عواملی اشاره دارند که به‌طور کلی بر سیستم اقتصادی و بانکی تأثیر می‌گذارند. تحلیل این متغیرها به بانک کمک می‌کند تا تأثیرات عوامل کلان اقتصادی بر تصمیمات اعتباری را در نظر بگیرد.

جدول ۱: معرفی متغیرهای تحقیق

دسته	متغیر	توضیح
	Customer ID	شناسه منحصر به فرد مشتری؛ به عنوان کلید اصلی داده‌ها برای اتصال استفاده می‌شود.
	Age	سن مشتری؛ شاخصی برای تجربه مالی و سابقه کاری
	Monthly Income	درآمد ماهانه مشتری؛ نشان دهنده توانایی پرداخت بدهی
	Credit Score	امتیاز اعتباری داخلی؛ برآورد بانک از ریسک اعتباری مشتری
متغیرهای درون‌سازمانی (اطلاعات بانکی)	Total Loans	تعداد وام‌های دریافتی؛ بیانگر تجربه مشتری در استفاده از تسهیلات مالی
	Loan Default History	سابقه عدم پرداخت وام؛ برای ارزیابی ریسک مشتری
	Monthly Transactions	تعداد تراکنش‌های ماهانه؛ نشان دهنده میزان استفاده از خدمات بانکی
	Account Balance	مانده حساب جاری؛ شاخصی برای نقدینگی مشتری
	Employment Status	وضعیت شغلی (شاغل، خوداشتغال، بیکار، بازنشسته)؛ نشانگر پایداری مالی مشتری
	Social Media Activity	سطح فعالیت در شبکه‌های اجتماعی؛ نشانگر تعامل و نفوذ اجتماعی
متغیرهای برون‌سازمانی (اطلاعات اعتباری و اجتماعی)	Customer Satisfaction Score	امتیاز رضایت مشتری از خدمات بانکی؛ نشان دهنده دیدگاه مشتری نسبت به خدمات
	Credit Report Score	امتیاز اعتباری از منابع بیرونی؛ تعیین اعتبارپذیری مشتری در سطح کلان
	Total Debt	کل بدهی‌های مشتری؛ نشانگر میزان تعهدات مالی
	Debt Repayment History	سابقه بازپرداخت بدهی؛ بیانگر تعهد و مسئولیت‌پذیری مالی مشتری
متغیرهای کلان عمومی (اطلاعات اقتصادی و محیطی)	Region Economic Growth	نرخ رشد اقتصادی منطقه‌ای؛ اثرگذار بر توانایی مالی مشتری
	Unemployment Rate	نرخ بیکاری منطقه‌ای؛ نشان دهنده وضعیت اشتغال در منطقه مشتری
	Inflation Rate	نرخ تورم؛ تاثیرگذار بر قدرت خرید مشتری
	Market Risk Index	شاخص ریسک بازار؛ نشانگر سطح ریسک اقتصادی منطقه

پاک‌سازی داده‌ها: اولین گام در پیش‌پردازش داده‌ها، پاک‌سازی آن‌ها از نویز و داده‌های ناقص است. داده‌های تکراری، داده‌های غیرمنطقی و مقادیر گم‌شده شناسایی و اصلاح می‌شوند. به عنوان مثال، داده‌های ناقص می‌توانند از طریق روش‌هایی مانند جایگزینی با میانگین یا حذف ردیف‌های ناقص رفع شوند.

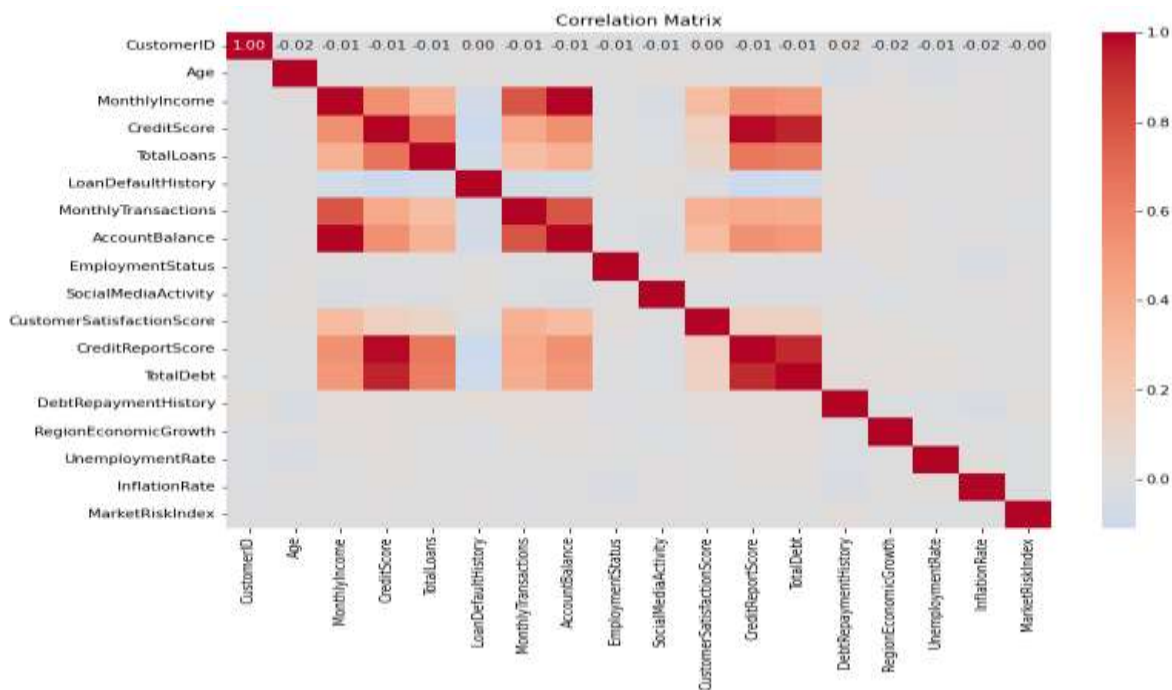
شکل ۱ نشان می‌دهد، ویژگی‌هایی که دارای داده‌های مفقود هستند شناسایی شده‌اند. همان‌طور که مشاهده می‌شود، برخی ویژگی‌ها مانند موجودی حساب (AccountBalance)، سن (Age) و نرخ تورم (InflationRate) بیشترین تعداد داده‌های مفقود را دارند. برای مدیریت این مقادیر مفقود، از روش جایگزینی با میانگین استفاده خواهد شد. به عبارت دیگر، مقادیر مفقود هر ویژگی با میانگین مقادیر

موجود آن ویژگی جایگزین می‌شود، تا یکپارچگی و کامل بودن داده‌ها در مراحل بعدی تحلیل و مدل‌سازی حفظ شود. این روش به کاهش سوگیری ناشی از داده‌های ناقص کمک کرده و بهبود کیفیت مدل نهایی را تضمین می‌کند.



شکل ۱: شناسایی داده‌های گمشده

در ادامه از تحلیل همبستگی به عنوان روشی برای انتخاب ویژگی‌های مهم استفاده شده است، بدون وجود متغیر هدف (که معمولاً در مدل‌های پیش‌بینی به عنوان خروجی یا نتیجه تعریف می‌شود). این روش در مواردی به کار می‌رود که مدل‌سازی با هدف تقسیم‌بندی یا خوشه‌بندی انجام می‌شود، و به جای پیش‌بینی متغیر خروجی، تمرکز بر روی شناسایی الگوها و روابط بین متغیرهای مستقل است. در شکل ۲، متغیرهایی که دارای همبستگی بالاتر از ۰٫۵ هستند، شناسایی و به عنوان ویژگی‌های مهم استخراج شده‌اند. این متغیرها نشان‌دهنده روابط قوی و معنادار بین داده‌ها بوده و در فرآیند مدل‌سازی مورد توجه قرار می‌گیرند. همچنین، مقادیر ضریب همبستگی برای هر یک از این متغیرهای مهم در جدول زیر آورده شده است تا میزان ارتباط آن‌ها با سایر متغیرها مشخص شود.



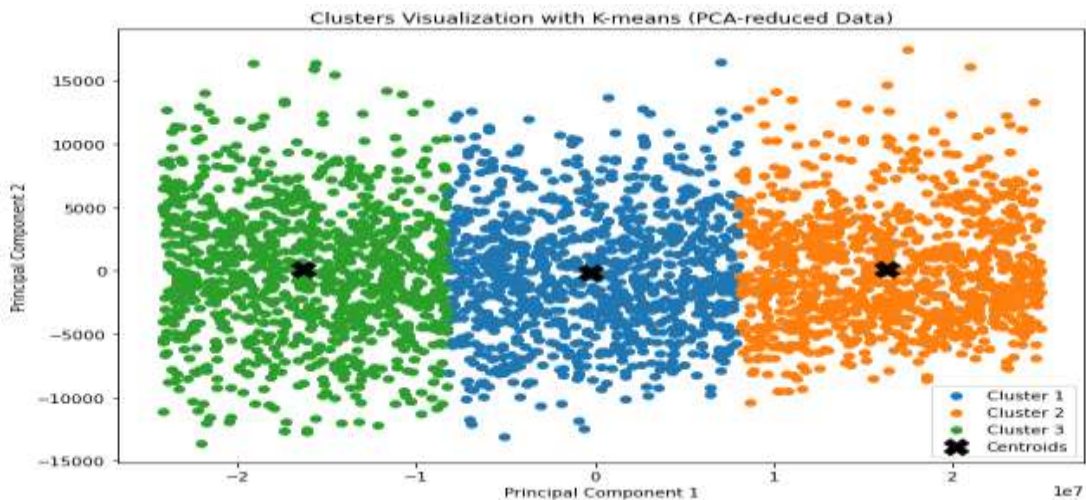
شکل ۲: نمودار ضریب همبستگی متغیرها

براساس نتایج محاسبات و تحلیل ضرایب همبستگی و با توجه به یافته‌های بدست آمده، متغیرهای کلیدی به شرح زیر شناسایی و استخراج گردیده‌اند:

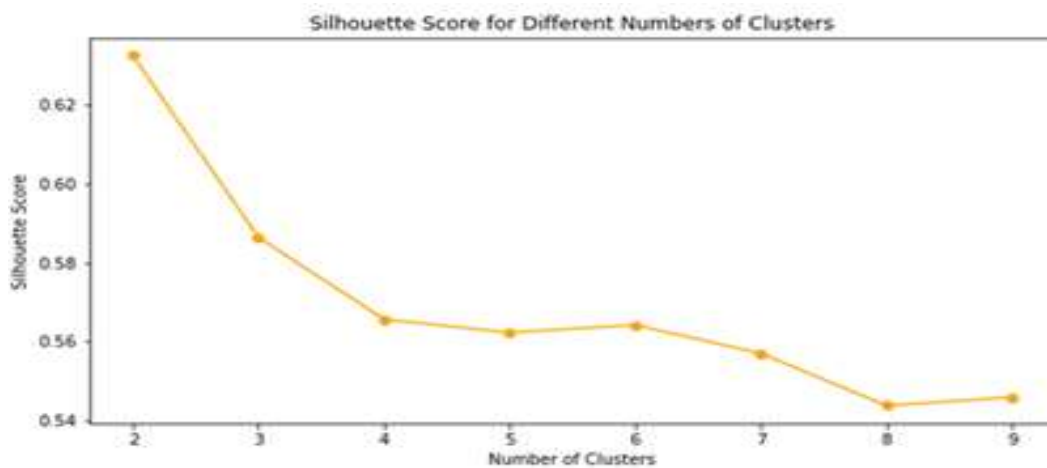
'TotalLoans', 'CreditScore', 'MonthlyTransactions', 'TotalDebt', 'AccountBalance', 'MonthlyIncome', 'CreditReportScore'

برای تحلیل دقیق مشتریان و تقسیم‌بندی آن‌ها، روش خوشه‌بندی به عنوان یکی از تکنیک‌های کاربردی در تحلیل داده‌ها و مدیریت ریسک مورد استفاده قرار گرفت. در این مطالعه، نظرات خبرگان حوزه مالی و اعتباری به عنوان یک منبع معتبر مورد بررسی قرار گرفت و بر اساس تحلیل‌های آن‌ها مشخص شد که دسته‌بندی مشتریان در سه خوشه، یعنی کم‌ریسک، ریسک متوسط، و پُرریسک، منطقی‌ترین ساختار برای مدیریت مؤثر ریسک اعتباری و بهینه‌سازی فرآیندهای اعطای تسهیلات است.

همچنین، نمای تصویری این تحلیل در شکل ۳ ارائه شده است که ساختار کلی خوشه‌بندی و کیفیت تفکیک هر خوشه را نمایش می‌دهد. این شکل تأیید می‌کند که هر سه خوشه انتخابی، هم از نظر توزیع داده‌ها و هم از نظر فاصله میان خوشه‌ها، ساختاری منطقی و علمی دارند. بنابراین، شاخص سیلوئیت با مقدار ۰,۵۸ و تحلیل تصویری در شکل ۴ اعتبار خوشه‌بندی و همچنین نظر خبرگان را تقویت کرده و به عنوان یکی از شواهد علمی در دفاع از مدل مورد استفاده در این تحقیق، به کار رفته است.



شکل ۳: ساختار کلی خوشه بندی

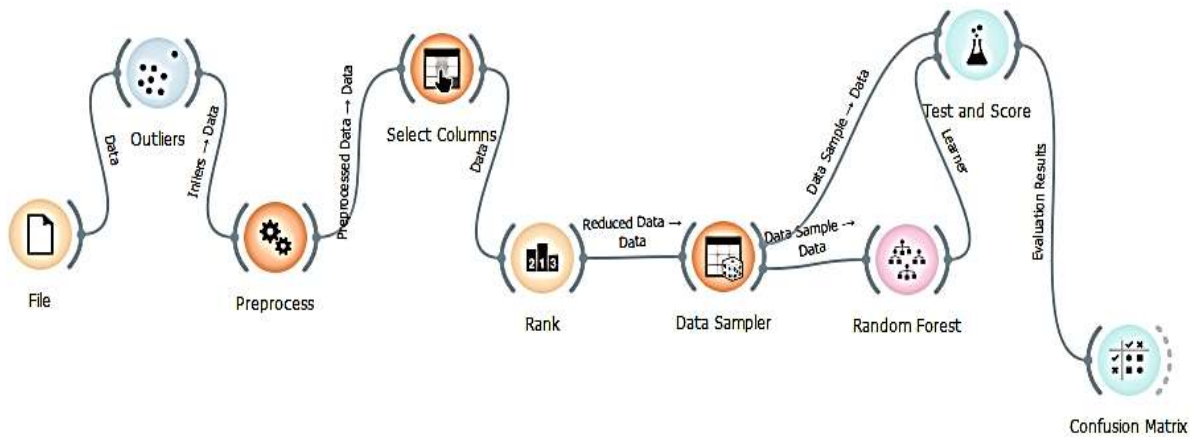


شکل ۴: شاخص سیلوئیت

با توجه به خوشه‌بندی انجام شده و تأیید اعتبار آن، ویژگی‌های هر یک از خوشه‌های سه‌گانه (کم‌ریسک، ریسک متوسط و پرریسک) با استفاده از تحلیل آماری توصیفی داده‌ها مشخص شد.

در ادامه مدلی برای پیش‌بینی ریسک اعتباری مشتریان طراحی شده است که بر اساس روش‌های پیشرفته یادگیری ماشین پیاده‌سازی گردیده است. هدف از این مدل، پیش‌بینی دقیق و مؤثر ریسک اعتباری مشتریان و تخصیص آن‌ها به گروه‌های مختلف ریسک (کم‌ریسک، ریسک متوسط، پرریسک) با توجه به ویژگی‌های مالی و اعتباری آنان است. برای رسیدن به این هدف، از یکی از الگوریتم‌های قدرتمند یادگیری ماشین به نام جنگل تصادفی (Random Forest) استفاده شده است که به دلیل دقت بالا و توانایی در مدیریت ویژگی‌های پیچیده و چندبعدی داده‌ها، برای این مدل مناسب می‌باشد.

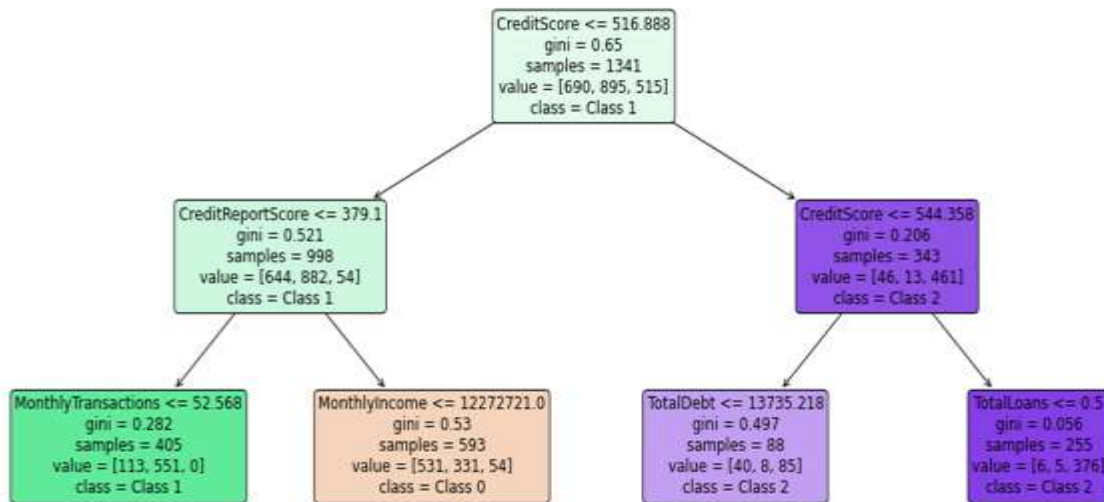
مدل طراحی شده در شکل ۵ نمایش داده شده است که ساختار کلی فرآیند پیش‌بینی ریسک را نشان می‌دهد. این مدل شامل چندین مرحله اصلی است که به طور مختصر به شرح آن‌ها پرداخته خواهد شد.



شکل ۵: ساختار مدل پیشنهادی

در واقع، با استفاده از ویژگی‌ها و شرایط حاصل از مدل، می‌خواهیم مشتریان را به این کلاس‌ها اختصاص دهیم. در شکل ۶ یکی از درخت‌های موجود در این جنگل تصادفی به همراه نتایج و تصمیم‌گیری‌های آن نمایش داده شده است. این درخت به وضوح نشان می‌دهد که چگونه ویژگی‌های مختلف داده‌ها بر روی تصمیم نهایی اثر می‌گذارند. با تحلیل این تصمیم‌گیری‌ها، می‌توانیم درک بهتری از فرآیند پیش‌بینی مدل و عواملی که تأثیرگذار بوده‌اند، پیدا کنیم.

Visualization of a Pruned Decision Tree in Random Forest



شکل ۶: درخت تصمیم‌گیری

تحلیل شکل ۶ به بررسی یک درخت تصمیم خاص از مدل جنگل تصادفی می‌پردازد که با استفاده از ویژگی‌های مالی، مشتریان را به دسته‌های مختلف طبقه‌بندی می‌کند. با دنبال کردن مسیرها در این درخت، می‌توانیم تصمیمات بهینه‌ای برای شناسایی کلاس‌های مشتریان اتخاذ کنیم.

ساختار درخت تصمیم و فرآیند طبقه‌بندی

۱. گره ریشه (Root Node):

$$\text{CreditScore} \leq 516.888 -$$

- اگر نمره اعتبار کمتر یا برابر با ۵۱۶,۸۸۸ باشد، به گره بعدی می‌رود؛ در غیر این صورت به سمت راست می‌رود.

۲. گره چپ:

$$\text{CreditReportScore} \leq 379.1 \bullet$$

• اگر نمره گزارش اعتبار کمتر یا برابر با ۳۷۹,۱ باشد، به گره‌های زیرین می‌رود:

$$\text{MonthlyTransactions} \leq 52.568 \bullet$$

• اگر تعداد تراکنش‌های ماهانه کمتر یا برابر با ۵۲,۵۶۸ باشد، مشتری به کلاس ۱ تعلق دارد.

• اگر $\text{CreditReportScore} > 379.1$ باشد، به گره بعدی می‌رسد:

$$\text{MonthlyIncome} \leq 12272721 \bullet$$

• اگر درآمد ماهانه کمتر یا برابر با ۱۲۲۷۲۷۲۱ باشد، به کلاس ۰ تعلق دارد.

۳. گره راست:

$$\text{CreditScore} \leq 544.358 \bullet$$

• اگر نمره اعتبار کمتر یا برابر با ۵۴۴,۳۵۸ باشد، به سمت زیرین می‌رود:

$$\text{TotalDebt} \leq 13735.218 \bullet$$

• اگر مجموع بدهی کمتر یا برابر با ۱۳۷۳۵,۲۱۸ باشد، به کلاس ۲ تعلق دارد.

• اگر بیشتر باشد، به گره‌های دیگر منتقل می‌شود.

با توجه به این تحلیل، مشتریان در سمت چپ درخت تصمیم به دو کلاس مختلف تعلق دارند:

کلاس ۱: برای مشتریانی که نمره اعتبار $\geq 516,888$ و نمره گزارش اعتبار $\geq 379,1$ و تعداد تراکنش‌های ماهانه $\geq 52,568$ دارند.
 کلاس ۰: برای مشتریانی که نمره اعتبار $\geq 516,888$ و نمره گزارش اعتبار $\leq 379,1$ و درآمد ماهانه $\geq 12,272,721$ ، آنگاه به کلاس ۰ تعلق دارند.

در این تحلیل، به بررسی یکی از ۱۰۰ درخت تصادفی تولید شده پرداخته‌ایم، در حالی که سایر درخت‌ها نیز به طور مشابه ایجاد شده و می‌توانند نتایج و الگوهای جالب و مفیدی را ارائه دهند. این تحلیل کمک می‌کند تا به وضوح مسیر تصمیم‌گیری را برای طبقه‌بندی مشتریان شناسایی کنیم و تصمیمات بهتری برای مدیریت ریسک و خدمات بهینه اتخاذ کنیم.

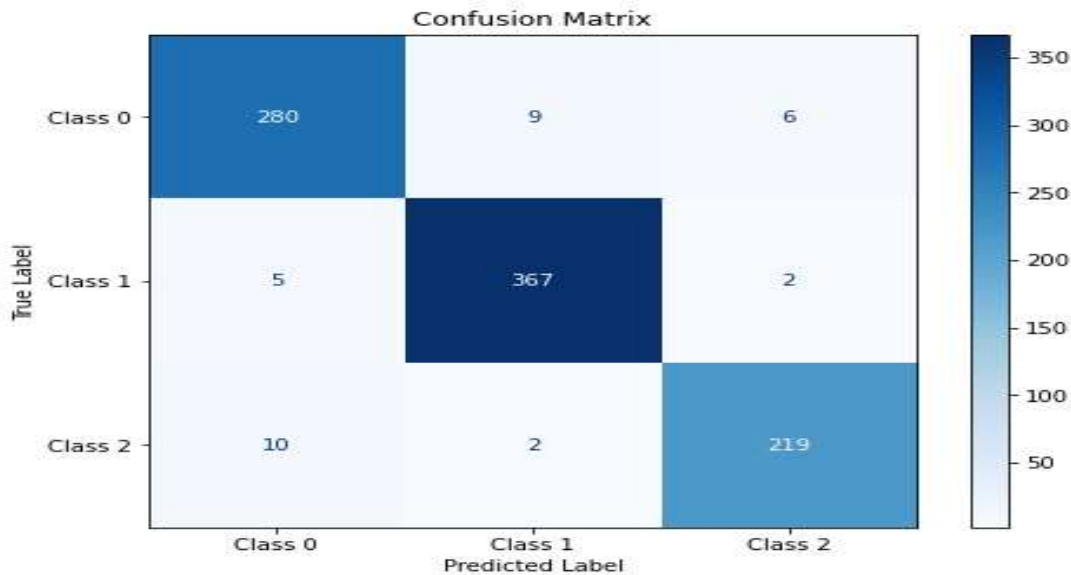
مدل درخت تصادفی که در این مطالعه پیاده‌سازی شده است، به منظور پیش‌بینی عملکرد بهینه، مورد ارزیابی قرار گرفته است. معیارهای مختلف ارزیابی به کار گرفته شده‌اند، که از جمله مهم‌ترین آن‌ها دقت (Accuracy) مدل است. پس از آموزش و تست مدل، دقت برابر با ۰,۹۶۲۲ بدست آمد. این مقدار دقت بیانگر آن است که مدل توانسته است به طور مؤثر ۹۶,۲۲٪ از نمونه‌ها را به درستی پیش‌بینی کند. چنین دقت بالایی نشان‌دهنده کیفیت بالای داده‌ها و قدرت یادگیری مدل در شناسایی الگوهای موجود در داده‌ها می‌باشد. علاوه بر این، دقت تقریباً نزدیک به ۱ (۱۰۰٪) می‌تواند حاکی از این باشد که مدل قادر به تعمیم مناسب به داده‌های جدید است. بنابراین، این نتایج

حاکمی از کارایی و قابلیت اطمینان بالای مدل درخت تصادفی در پیش‌بینی نتایج است، و این مدل می‌تواند به عنوان یک ابزار قوی برای تحلیل و پیش‌بینی در موارد مشابه به کار گرفته شود.

همچنین طبق ماتریس سردرگمی در شکل ۷ درصد درست پیش‌بینی‌ها به شرح زیر است:

- Class 0: 280 از ۲۹۵ پیش‌بینی صحیح (۹۴٫۹۱ درصد).
- Class 1: 367 از ۳۷۴ پیش‌بینی صحیح (۹۸٫۱۳ درصد).
- Class 2: 219 از ۲۳۱ پیش‌بینی صحیح (۹۴٫۸۱ درصد).

این درصدها نشان می‌دهند که مدل در شناسایی هر یک از کلاس‌ها دارای دقت بالایی است، به خصوص در Class 1 با ۹۸٫۱۳ درصد، که بیانگر توانایی بسیار خوب مدل در شناسایی این کلاس خاص است. به طور کلی، این نتایج به وضوح نشان‌دهنده عملکرد خوب مدل هستند و می‌توانند به عنوان معیارهای مؤثر برای ارزیابی کارایی آن در رسیدن به نتایج مطلوب استفاده شوند.



شکل ۷: ماتریس سردرگمی

در ادامه، با استفاده از مدل جنگل تصادفی که بر اساس هفت ویژگی کلیدی شامل [اکل وام‌ها، امتیاز اعتبار، تراکنش‌های ماهانه، اکل بدهی، موجودی حساب، درآمد ماهانه و امتیاز گزارش اعتباری] آموزش داده شده است، پیش‌بینی داده‌های جدید انجام گرفت. این مدل علاوه بر پیش‌بینی کلاس نهایی (تخصیص وام)، احتمال تعلق هر نمونه به هر یک از سه کلاس تعریف شده را نیز ارائه می‌دهد. برای پیش‌بینی داده‌های جدید، نمونه‌هایی از داده‌ها با مقادیر مشخص برای هر یک از متغیرهای ورودی به مدل داده شد. علاوه بر کلاس تخصیص یافته، احتمال تعلق هر نمونه به هر یک از کلاس‌های سه‌گانه را نیز محاسبه کرد. این احتمالات نشان‌دهنده میزان اطمینان مدل در پیش‌بینی خود هستند و می‌توانند به تصمیم‌گیرندگان کمک کنند تا تخصیص وام را بهینه‌تر انجام دهند. جدول زیر نمونه‌ای از داده‌های جدید همراه با کلاس پیش‌بینی شده و احتمالات مربوطه را نمایش می‌دهد:

جدول ۲: نتایج پیش بینی داده های جدید

کلاس احتمال ۲	کلاس احتمال ۱	کلاس احتمال ۰	کلاس پیش‌بینی‌شده	امتیاز گزارش اعتباری	درآمد ماهانه	موجودی حساب	کل بدهی	تراکنش‌های ماهانه	امتیاز اعتبار	کل وام‌ها
۰	۰,۰۵	۰,۹۵	صفر	۲۸۵,۶۳	۱۶۴۳۳۳۲۴	۳۳۸۸۶۹۰۰	۴۳۱۰,۳۵	۵۴	۳۰۱	۰
۰,۹۹	۰	۰,۰۱	دو	۵۹۱,۵	۲۴۱۲۳۴۵۶	۴۵۶۳۲۴۸۹	۱۷۴۵۶,۵	۶۶	۵۷۱,۴۴	۵
۰	۰,۹۱	۰,۰۹	یک	۳۱۵,۴۵	۱۴۳۲۵۳۶۹	۱۸۶۹۸۵۴۷	۵۶۲۱,۴۵	۳۲,۲۱	۳۲۱,۴۴	۲
۰	۰,۱۵	۰,۸۵	صفر	۲۹۰,۶۳	۱۶۴۳۳۹۱۹	۳۳۸۸۶۹۰۰	۵۳۱۰,۳۵	۵۱,۹	۳۰۰	۰

در این جدول، کلاس پیش‌بینی‌شده بر اساس بالاترین احتمال تعیین شده و نشان‌دهنده تصمیم مدل است. همچنین مقادیر احتمالات، امکان تحلیل دقیق‌تر را برای کاربران فراهم می‌کند تا تصمیم‌گیری‌های خود را بر اساس داده‌های مدل بهینه‌سازی کنند. در راستای بهینه‌سازی تصمیم‌گیری برای تخصیص تسهیلات بانکی، استفاده از روش‌های تصمیم‌گیری چندمعیاره (MCDM) به بانک‌ها این امکان را می‌دهد که منابع مالی خود را به شکل مؤثرتری توزیع کنند. روش فرایند تحلیل سلسله‌مراتبی (AHP) یکی از ابزارهای قدرتمند در این زمینه است که با وزن‌دهی معیارهای کلیدی، اولویت‌های تصمیم‌گیری را مشخص می‌کند. برای تعیین وزن معیارهای تصمیم‌گیری در روش تحلیل سلسله‌مراتبی (AHP)، ابتدا ماتریس مقایسات زوجی بر اساس نظرات پنج نخبه مالی و بانکی با تجربه در حوزه تخصیص تسهیلات تکمیل شد. این خبرگان با توجه به دانش و تجربیات خود، اهمیت نسبی هر معیار را نسبت به معیارهای دیگر در مقیاس ۱ تا ۵ تعیین کردند.

جدول ۳: نتایج وزن‌دهی نهایی معیارها

وزن	معیار
۰,۲۲۳۶۷۹	کل وام‌های دریافتی
۰,۱۷۸۷۲۴	تعداد تراکنش‌های ماهانه
۰,۱۶۲۷۷۸	امتیاز اعتباری
۰,۱۵۲۰۳۹	درآمد ماهانه
۰,۱۰۹۶۹۵	کل بدهی
۰,۱۰۴۲۲۴	امتیاز گزارش اعتباری
۰,۰۶۸۸۶۰	موجودی حساب

همان‌طور که جدول ۳ نشان می‌دهد، معیار "کل تسهیلات اعطایی" با وزن ۰,۲۲۳۶۷۹ بالاترین اهمیت را دارد، که نشان‌دهنده ارتباط مستقیم این شاخص با ریسک و توان بازپرداخت مشتریان است. معیارهای "تعداد تراکنش‌های ماهانه" (۰,۱۷۸۷۲۴) و "امتیاز اعتباری" (۰,۱۶۲۷۷۸) نیز از اهمیت بالایی برخوردارند، که به فعالیت‌های مالی و سلامت اعتباری مشتری توجه ویژه‌ای دارند. در مقابل، معیارهایی مانند "موجودی حساب" (۰,۰۶۸۸۶۰) و "امتیاز گزارش اعتباری" (۰,۱۰۴۲۲۴) وزن کمتری دارند، اما همچنان نقش مکملی در ارزیابی مشتری ایفا می‌کنند.

یکی از مهم‌ترین شاخص‌ها در اعتبارسنجی نتایج AHP، نسبت سازگاری است که در این تحلیل برابر با ۰,۰۸۱۳ محاسبه شده است. از آنجا که این مقدار کمتر از آستانه قابل قبول ۰,۱ است، قضاوت‌های مقایسه‌ای انجام‌شده در ماتریس‌های زوجی دارای سازگاری مطلوبی هستند. این موضوع دقت و صحت وزن‌دهی معیارها را تأیید می‌کند.

در ادامه، از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) برای تعیین مقدار بهینه تسهیلات بانکی بر اساس مجموعه‌ای از متغیرهای کلیدی استفاده شده است. این متغیرها شامل کل وام‌ها، امتیاز اعتبار، تعداد تراکنش‌های ماهانه، کل بدهی، موجودی حساب، درآمد ماهانه و امتیاز گزارش اعتباری هستند که هر یک با محدوده مشخص تعریف شده‌اند. که در جدول زیر برای هر متغیر محدوده‌ای براساس داده‌های واقعی تعیین کرده‌ایم. تابع هدف طراحی شده در این الگوریتم به دنبال بیشینه‌سازی مقدار وام است به طوری که عوامل مرتبط با ریسک و بازدهی مالی بانک نیز در نظر گرفته شوند. در واقع هدف این است که حداکثر مقدار تسهیلات بانکی را تعیین کنیم تا، سود بانک افزایش و در عین حال ریسک عدم پرداخت وام را کاهش دهد.

جدول ۴: تعیین حدود متغیرها

متغیر	حد پایین	حد بالا
کل وام‌های دریافتی	۰	۵
تعداد تراکنش‌های ماهانه	۱	۹۴,۸۴
امتیاز اعتباری	۳۰۰	۸۵۰
درآمد ماهانه	۳۰۰۹۱۷	۲۴۹۹۴۳۰۰
کل بدهی	۰	۳۲۵۶۱,۱۳
امتیاز گزارش اعتباری	۲۴۴,۰۶	۸۷۰,۶۹
موجودی حساب	۶۰۲۰۵۸۷,۲۶	۵۰۰۰۸۸۹۱,۴

با استفاده از PSO، محدوده‌های مشخص برای هر متغیر به عنوان ورودی تعیین شده و با تنظیمات الگوریتم مانند اندازه جمعیت (swarmsize) و تعداد تکرارها (maxiter)، بهترین ترکیب از مقادیر متغیرها برای ارائه مقدار تسهیلات بهینه به دست آمده است. خروجی‌های الگوریتم شامل مقادیر بهینه متغیرها و بیشینه مقدار تسهیلات ممکن است که بر اساس شرایط ورودی محاسبه می‌شود. این روش به بانک کمک می‌کند تا تصمیمات بهینه‌تری در زمینه اعطای وام به مشتریان مختلف اتخاذ کند. بعد از اجرای مدل مقادیر بهینه‌ای که الگوریتم PSO برای متغیرهای ورودی پیدا کرده است به صورت زیر می‌باشد

کل وام‌ها: ۰,۴۷۱۶، امتیاز اعتبار: ۸۵۰ (حداکثر مقدار ممکن برای امتیاز اعتبار)، تعداد تراکنش‌های ماهانه: ۹۴,۸۴ (حداکثر مقدار ممکن برای تعداد تراکنش‌ها)، کل بدهی: ۰ (هیچ بدهی فعالی ثبت نشده است)، موجودی حساب: ۵۰,۰۰۸,۸۹۱,۴ (حداکثر مقدار ممکن برای موجودی حساب)، درآمد ماهانه: ۲۴,۹۹۴,۳۰۰ (حداکثر مقدار ممکن برای درآمد ماهانه)، امتیاز گزارش اعتباری: ۸۷۰,۶۹ (حداکثر مقدار ممکن برای گزارش اعتباری)، بنابراین حداکثر مقدار وامی که تعلق گرفته برابر است با Maximum loan amount: 7,500,677.504

این مقدار نشان‌دهنده بیشینه تسهیلاتی است که بانک می‌تواند به مشتری تحت این شرایط اعطا کند. الگوریتم PSO بر اساس داده‌های ورودی و تابع هدف تعریف شده، مقدار ۷,۵۰۰,۶۷۷,۵۰۴ را به عنوان حداکثر مبلغ تسهیلات محاسبه کرده است. این مقدار با توجه به شرایط مشتری بهینه شده است تا بانک بتواند بیشترین سود را کسب کند. و ریسک عدم بازپرداخت به حداقل برسد. در نهایت الگوریتم PSO توانسته است بر اساس متغیرهای ورودی و شرایط تعریف شده، حداکثر مقدار تسهیلات بانکی را به طور مؤثر بهینه‌سازی کند. نتایج نشان می‌دهند که مشتری دارای شرایط اعتباری و مالی بسیار مطلوبی است و می‌تواند بالاترین مقدار تسهیلات ممکن را دریافت کند. این مدل می‌تواند به عنوان ابزاری قابل اعتماد در تصمیم‌گیری‌های اعطای تسهیلات بانکی به کار رود.

اعتبارسنجی الگوریتم PSO معمولاً از طریق ارزیابی پایداری و تکرارپذیری نتایج انجام می‌شود. در این روش، الگوریتم PSO چندین بار با داده‌ها و شرایط اولیه یکسان اجرا می‌شود و خروجی‌ها با یکدیگر مقایسه می‌شوند. اگر نتایج حاصل از اجراهای متعدد مشابه باشند، نشان‌دهنده پایداری الگوریتم و توانایی آن در یافتن بهینه‌های قابل اعتماد است. از سوی دیگر، اگر نتایج تفاوت زیادی داشته باشند، این ممکن است به ضعف در تنظیم پارامترهای الگوریتم یا عدم تطابق آن با مسئله مورد بررسی اشاره داشته باشد. در پژوهش حاضر، این روش اعتبارسنجی به کار گرفته شد. الگوریتم PSO با داده‌های یکسان و شرایط مشابه چندین بار اجرا شد و در تمامی اجراها نتایج به طور مداوم یکسان به دست آمد.

این موضوع نشان‌دهنده نکات زیر است:

۱. پایداری الگوریتم
۲. تکرارپذیری نتایج
۳. تحلیل علمی نتایج یکسان
۴. اهمیت و پیامدهای پایداری الگوریتم

بنابراین اعتبارسنجی الگوریتم PSO از طریق اجرای مکرر و مقایسه نتایج نشان داد که این الگوریتم در مسئله مورد بررسی از پایداری و تکرارپذیری بالایی برخوردار است. نتایج یکسان به دست آمده در هر بار اجرا تأیید می‌کند که تنظیمات الگوریتم به درستی انجام شده و تابع هدف به شکلی مناسب تعریف شده است. این امر اطمینان می‌دهد که الگوریتم PSO توانایی بالایی در حل مسائل بهینه‌سازی مرتبط با این پژوهش دارد و نتایج آن قابل اعتماد و معتبر است.

نتیجه گیری

این پژوهش با هدف طراحی و پیاده‌سازی یک مدل هوشمند برای اعطای تسهیلات بانکی مبتنی بر کلان‌داده، توانسته است گامی مؤثر در جهت بهبود فرآیند تصمیم‌گیری بانک‌ها بردارد. مدل ارائه‌شده شامل مراحل کلیدی مانند جمع‌آوری و پیش‌پردازش داده‌ها، خوشه‌بندی مشتریان، پیش‌بینی ریسک اعتباری و بهینه‌سازی تصمیمات است که با استفاده از الگوریتم‌های پیشرفته، دقت و کارایی بالایی را به همراه داشته است.

در مرحله اول، پیش‌پردازش داده‌ها با تمرکز بر پاک‌سازی و استانداردسازی، کیفیت داده‌ها را بهبود بخشیده و امکان تحلیل دقیق‌تری را فراهم کرده است. مرحله دوم، خوشه‌بندی مشتریان با الگوریتم K-Means، توانسته است گروه‌های مشتریان را بر اساس ریسک اعتباری به سه دسته کم‌ریسک، ریسک متوسط و پرریسک تقسیم کند، که پایه‌ای برای تخصیص بهینه منابع بوده است. در ادامه، با استفاده از مدل جنگل تصادفی، ریسک اعتباری مشتریان با دقت ۹۶٫۲۲٪ پیش‌بینی شده که نقش بسزایی در کاهش ریسک تسهیلات اعطایی ایفا کرده است. در نهایت، ترکیب تکنیک‌های AHP و PSO برای بهینه‌سازی فرآیند تخصیص تسهیلات، تصمیم‌گیری بانک‌ها را به شکلی کارآمد و علمی تسهیل کرده است.

تحلیل نظرات خبرگان نشان داد که علی‌رغم وجود چالش‌هایی مانند زیرساخت‌های ناکافی و نیاز به آموزش کارکنان، پیاده‌سازی این مدل با بهبود زیرساخت‌ها و ارتقای فرهنگ سازمانی امکان‌پذیر است. همچنین، امنیت اطلاعات به‌عنوان یک ضرورت اصلی مطرح شده و توجه به این موضوع برای حفظ اعتماد مشتریان ضروری است.

به‌طور کلی، این پژوهش نشان داد که استفاده از کلان‌داده و تکنیک‌های هوشمند در ارزیابی صلاحیت اعتباری مشتریان می‌تواند منجر به بهبود فرآیند اعطای تسهیلات، کاهش ریسک، و افزایش بهره‌وری بانک‌ها شود. نتایج این مطالعه می‌تواند به‌عنوان الگویی برای پیاده‌سازی سیستم‌های مشابه در سایر بانک‌ها و سازمان‌های مالی مورد استفاده قرار گیرد.

برای تحقق اهداف مدل هوشمند اعطای تسهیلات بانکی مبتنی بر کلان‌داده و اطمینان از موفقیت آن در فضای عملیاتی، اجرای راهکارهای عملی و علمی ضروری است. این راهکارها باید با تمرکز بر بهبود زیرساخت‌ها، آموزش کارکنان، و مدیریت کارآمد داده‌ها تدوین شوند تا علاوه بر افزایش بهره‌وری بانک‌ها، رضایت مشتریان نیز بهبود یابد. در ادامه، مهم‌ترین پیشنهادات ارائه می‌شوند.

برای پیاده‌سازی موفق مدل هوشمند اعطای تسهیلات بانکی، بهبود زیرساخت‌های فناوری از جمله سرورهای پر قدرت، سیستم‌های ذخیره‌سازی توزیع‌شده و نرم‌افزارهای تحلیل کلان‌داده ضروری است. امنیت داده‌ها باید با استفاده از روش‌هایی نظیر رمزنگاری پیشرفته، سیستم‌های تشخیص نفوذ و رعایت الزامات استانداردهای امنیت اطلاعات (مانند ISO 27001) تضمین شود تا از اطلاعات حساس مشتریان محافظت شود.

برای پذیرش و بهره‌برداری صحیح از مدل پیشنهادی، لازم است کارکنان بانک‌ها در حوزه‌های کلان‌داده، یادگیری ماشین و تحلیل پیشرفته داده‌ها آموزش ببینند. برگزاری کارگاه‌ها و دوره‌های آموزشی برای مدیران و کارشناسان، آگاهی آنان را از مزایا و نحوه استفاده از مدل افزایش می‌دهد.

توجه ویژه به پاک‌سازی، استانداردسازی و یکپارچه‌سازی داده‌ها از منابع داخلی و خارجی ضروری است. توسعه پروتکل‌های دقیق برای جمع‌آوری داده‌ها از سیستم‌های بانکی، شبکه‌های اجتماعی و منابع دیگر می‌تواند کیفیت تحلیل‌ها را بهبود بخشد. همچنین، استفاده از ابزارهای پیشرفته نظیر Apache Spark برای پیش‌پردازش و مدیریت داده‌ها پیشنهاد می‌شود.

بانک‌ها باید سیاست‌هایی شفاف و مبتنی بر مدل‌های تحلیلی در زمینه تخصیص تسهیلات ارائه دهند. این سیاست‌ها باید به گونه‌ای طراحی شوند که مشتریان کم‌ریسک به تسهیلات بیشتری دسترسی داشته باشند و بانک‌ها بتوانند منابع خود را بهینه مدیریت کنند.

برای کاهش ریسک‌های پیاده‌سازی، پیشنهاد می‌شود مدل ابتدا به صورت آزمایشی در یک یا چند شعبه منتخب اجرا شود. این مرحله امکان ارزیابی عملکرد مدل، شناسایی چالش‌ها و انجام اصلاحات لازم را فراهم می‌کند.

بانک‌ها می‌توانند از همکاری با شرکت‌های فعال در حوزه تحلیل داده و هوش مصنوعی بهره‌مند شوند. این همکاری‌ها می‌تواند به تسریع فرآیند پیاده‌سازی مدل و بهبود دقت آن کمک کند.

بانک‌ها می‌توانند از نتایج مدل برای تحلیل رفتار مشتریان، پیش‌بینی ریسک و جلوگیری از بدهی‌های معوق استفاده کنند. این امر نه تنها باعث کاهش ریسک‌های مالی می‌شود بلکه شفافیت بیشتری در تصمیم‌گیری‌های اعتباری ایجاد می‌کند.

برای پذیرش گسترده مدل، لازم است فرهنگ سازمانی بانک‌ها به سمت استقبال از نوآوری و فناوری‌های جدید سوق داده شود. این امر با برگزاری نشست‌های داخلی، ارائه مزایای مدل و تاکید بر اهمیت تحول دیجیتال امکان‌پذیر است.

پیشنهاد می‌شود مراجع نظارتی و سیاست‌گذار بانکداری، قوانین و مقررات حمایتی برای استفاده از مدل‌های هوشمند تدوین کنند. این قوانین باید شامل الزام به رعایت اخلاق داده، حفظ حریم خصوصی مشتریان و شفافیت در استفاده از الگوریتم‌های هوش مصنوعی باشند.

بانک‌ها باید ابزارهایی برای پایش عملکرد مدل و دریافت بازخورد از کاربران و مشتریان توسعه دهند. این ابزارها می‌توانند به بهبود مداوم مدل و افزایش رضایت مشتریان کمک کنند.

اجرای این راهکارها می‌تواند تضمین‌کننده موفقیت مدل پیشنهادی در فضای عملیاتی بانک‌ها باشد و نقش کلیدی در افزایش بهره‌وری و کاهش ریسک‌های اعتباری ایفا کند.

منابع:

- Owusu Kwateng, K., Agyei, J., & Amanor, K. (2019). Examining the efficiency of IT applications and bank performance. *Industrial Management & Data Systems*, 119(9), 2072-2090.
- Gaayire, R., Nikoi, S. N., & Adams, R. (2023). Improving banking and financial services in Ghana with big data analytics, A case study of amantin and kasei community bank. *International Journal of Latest Technology in Engineering & Management (IJLTEM)*, 8(2), 7-13.
- Isenberg, D. T., Sazu, M. H., & Jahan, S. A. (2022). How Banks Can Leverage Credit Risk Evaluation to Improve Financial Performance. *CECCAR Business Review*, 3(9), 62-72.
- Eni, L. N., Chaudhary, K., Raparathi, M., & Reddy, R. Evaluating the Role of Artificial Intelligence and Big Data Analytics in Indian Bank Marketing. *Tuijin Jishu/Journal of Propulsion Technology*, 44(3).
- Wibisono, O., Ari, H. D., Widjanarti, A., Zulen, A. A., & Tissot, B. (2019). The use of big data analytics and artificial intelligence in central banking. *IFC Bulletins, Bank for International Settlements*.
- Sazu, M. H., & Jahan, S. A. (2022). Impact of blockchain-enabled analytics as a tool to revolutionize the banking industry. *Data Science in Finance and Economics*, 2(3), 275-293.
- Addy, W. A., Ugochukwu, C. E., Oyewole, A. T., Ofodile, O. C., Adeoye, O. B., & Okoye, C. C. (2024). Predictive analytics in credit risk management for banks: A comprehensive review. *GSC Advanced Research and Reviews*, 18(2), 434-449.
- Chang, V., Hahm, N., Xu, Q. A., Vijayakumar, P., & Liu, L. (2024). Towards data and analytics driven B2B-banking for green finance: A cross-selling use case study. *Technological Forecasting and Social Change*, 206, 123542.
- Salleh, K. A., & Janczewski, L. (2019). Security considerations in big data solutions adoption: Lessons from a case study on a banking institution. *Procedia Computer Science*, 164, 168-176.
- Sazu, M. H., & Jahan, S. A. (2022). How Big Data Analytics is transforming the finance industry. *Bankarstvo*, 51(2), 147-172.
- Shoetan, P. O., Oyewole, A. T., Okoye, C. C., & Ofodile, O. C. (2024). Reviewing the role of big data analytics in financial fraud detection. *Finance & Accounting Research Journal*, 6(3), 384-394.
- Ahmadi, S. (2024). A comprehensive study on integration of big data and AI in financial industry and its effect on present and future opportunities. *International Journal of Current Science Research and Review*, 7(01), 66-74.
- Mohammed, A. B., Al-Okaily, M., Qasim, D., & Al-Majali, M. K. (2024). Towards an understanding of business intelligence and analytics usage: Evidence from the banking industry. *International Journal of Information Management Data Insights*, 4(1), 100215.
- Olabanji, S. O., Oladoyinbo, O. B., Asonze, C. U., Oladoyinbo, T. O., Ajayi, S. A., & Olaniyi, O. O. (2024). Effect of adopting AI to explore big data on personally identifiable information (PII) for financial and economic data transformation. Available at SSRN 4739227.
- Hung, J. L., He, W., & Shen, J. (2020). Big data analytics for supply chain relationship in banking. *Industrial Marketing Management*, 86, 144-153.
- Indriasari, E., Gaol, F. L., & Matsuo, T. (2019, July). Digital banking transformation: Application of artificial intelligence and big data analytics for leveraging customer experience in the Indonesia banking sector. In *2019 8th International Congress on Advanced Applied Informatics (IIAI-AAI)* (pp. 863-868). IEEE.
- Al-Dmour, H., Saad, N., Basheer Amin, E., Al-Dmour, R., & Al-Dmour, A. (2023). The influence of the practices of big data analytics applications on bank performance: filed study. *VINE Journal of Information and Knowledge Management Systems*, 53(1), 119-141.
- Ali, Q., Salman, A., Yaacob, H., Zaini, Z., & Abdullah, R. (2020). Does big data analytics enhance sustainability and financial performance? The case of ASEAN banks. *The Journal of Asian Finance, Economics and Business*, 7(7), 1-13.

- AL-Khatib, A. W. (2022). Intellectual capital and innovation performance: the moderating role of big data analytics: evidence from the banking sector in Jordan. *EuroMed Journal of Business*, 17(3), 391-423.
- Liao, K., Ma, C., Zhang, J., & Wang, Z. (2024). Does big data infrastructure development facilitate bank fintech innovation? Evidence from China. *Finance Research Letters*, 65, 105540.
- Liu, Y., Li, X., & Zheng, Z. (2024). Smart natural disaster relief: Assisting victims with artificial intelligence in lending. *Information Systems Research*, 35(2), 489-504.
- Mahgoub, A. (2024). Optimizing Bank Loan Approval with Binary Classification Method and Deep Learning Model. *Open Journal of Business and Management*, 12(3), 1970-2001.
- Sadok, H., & Assadi, D. (2024). The contribution of AI-Based analysis and rating models to financial inclusion: the Lenddo case for women-led SMEs in developing countries. In *Artificial Intelligence, Fintech, and Financial Inclusion* (pp. 11-25). CRC Press.
- Kang, J. K. (2024). Gone with the big data: Institutional lender demand for private information. *Journal of Accounting and Economics*, 77(2-3), 101663.
- Yin, X. (2024). The Effects of Big Data on Commercial Banks. Available at SSRN 4784409.
- Shi, B., Bai, C., & Dong, Y. (2024). A big data analytics method for assessing creditworthiness of SMEs: fuzzy equifinality relationships analysis. *Annals of Operations Research*, 1-31.
- Wang, J., Deng, H., & Zhao, X. (2024). Big data, green loans and energy efficiency. *Gondwana Research*.
- Saaty, T. L. (1980). *The analytic hierarchy process: Planning, priority setting, resource allocation*. McGraw-Hill.