

رتبه‌بندی اعتباری مبتنی بر یادگیری عمیق حساس به هزینه: ارائه چارچوب ترکیب وزنی بهینه الگوریتم‌های ناهمگن

نوع مقاله: پژوهشی

مهدی فرضی^۱، یعقوب پورکریم^۲، سید علی پایتخی اسکویی^۳، مهدی زینالی^۴، رسول برادران حسن زاده^۵

چکیده:

رتبه‌بندی اعتباری فرایندی است که توسط تسهیلات دهندگان، مانند بانک‌ها یا شرکت‌های کارت اعتباری، برای ارزیابی توانایی یک فرد یا کسب و کار در پرداخت تسهیلات اعتباری استفاده می‌شود. ارزیابی توانایی پرداخت از طریق ارزیابی عوامل مختلفی از جمله سابقه پرداخت، استفاده از اعتبار، مدت زمان سابقه اعتباری و نوع اعتبار مصرفی انجام می‌گیرد. مدل‌های مختلفی برای رتبه‌بندی اعتباری وجود دارند که با استفاده از الگوریتم‌های پیچیده، امتیاز اعتباری را محاسبه می‌کنند. استفاده از یادگیری عمیق در حوزه رتبه‌بندی اعتباری مشتریان با توجه به دقت بالای آن رشد فزاینده‌ای در ادبیات مربوط به این حوزه داشته است. در این میان، شبکه عصبی عمیق LSTM با توجه به لایه فراموشی که دارد، دارای حافظه بلند مدت بوده و در نتیجه یادگیری بسیار قوی نسبت به شبکه‌های عصبی مشابه دارد. در این پژوهش، یک مدل یادگیری عمیق یکپارچه برای رتبه‌بندی اعتباری مشتریان بانک ارائه شده است که بر پایه یادگیری جمعی (Ensemble Learning) و بهینه‌سازی همزمان پارامترها و انتخاب ویژگی با استفاده از الگوریتم ژنتیک (GA) طراحی شده است. در مدل پیشنهادی چهار الگوریتم Bagging، AdaBoost، Random Forest و LSTM به‌طور مستقل عمل کرده و خروجی‌های آن‌ها به وسیله ترکیب وزنی خطی ادغام می‌شوند. ارزیابی عملکرد مدل پیشنهادی بر روی سه مجموعه داده استاندارد از ایران، استرالیا و آلمان نشان می‌دهد که روش پیشنهادی، بهبود قابل توجهی از نظر دقت (ACC)، صحت (Precision)، فراخوانی (Recall)، شاخص F1 و کاهش خطاهای طبقه‌بندی (MC) ارائه می‌دهد این نتایج در مقایسه با مطالعات پیشین در سال‌های ۲۰۲۳ تا ۲۰۲۵ نشان‌دهنده پتانسیل بالای مدل پیشنهادی در بهبود تصمیم‌گیری‌های اعتباری و کاهش ریسک‌های مرتبط با عدم بازپرداخت شده و زمینه پایداری مالی برای بانک‌ها را فراهم می‌سازد.

واژه‌های کلیدی: رتبه‌بندی اعتباری - یادگیری عمیق - شبکه LSTM - یادگیری گروهی - الگوریتم ژنتیک - پایداری مالی

^۱ mehdi.farzi3357@iaut.ac.ir

^۲ pour Karim @ iaut.ac.ir

^۳ oskooe@iaut.ac.ir

^۴ zeynali@iaut.ac.ir

^۵ baradaran313@iaut.ac.ir

^۱ گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

^۲ گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

^۳ گروه اقتصاد، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

^۴ گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

^۵ گروه حسابداری، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران

Abstract:

Credit rating is a process used by lenders, such as banks or credit card companies, to assess the ability of an individual or business to repay credit facilities. This assessment is conducted by evaluating various factors, including payment history, credit utilization, credit history length, and the types of credit used. Several models exist for credit rating, which employ complex algorithms to calculate credit scores. The application of deep learning in customer credit rating has witnessed significant growth in the related literature due to its high accuracy. Among deep learning models, the Long Short-Term Memory (LSTM) neural network, due to its forget gate mechanism, possesses long-term memory capabilities and consequently exhibits stronger learning performance compared to similar neural networks.

In this study, an integrated deep learning model for customer credit rating in the banking sector is proposed, designed based on ensemble learning and simultaneous parameter optimization and feature selection using the Genetic Algorithm (GA). In the proposed model, four algorithms—AdaBoost, Bagging, Random Forest, and LSTM—operate independently, and their outputs are combined using a weighted linear aggregation approach. The model's performance evaluation on three benchmark datasets from Iran, Australia, and Germany demonstrates significant improvements in accuracy (ACC), precision, recall, F1-score, and reduced misclassification errors (MC). Compared to previous studies conducted between 2023 and 2025, the proposed model exhibits substantial potential for enhancing credit decision-making and mitigating risks associated with loan defaults, thereby contributing to financial sustainability for banks.

Keywords: Credit rating, deep learning, LSTM network, ensemble learning, genetic algorithm, financial sustainability.

مقدمه

بانک‌ها به عنوان موتور محرکه اقتصاد، با تجهیز پس‌اندازها و تخصیص آنها به فعالیت‌های تولیدی و تجاری، نقشی حیاتی در رشد اقتصادی ایفا می‌کنند. اما ذات این فعالیت‌ها با ریسک اعتباری گره خورده است؛ ریسکی که ناشی از احتمال عدم بازپرداخت تسهیلات توسط وام‌گیرندگان است و در صورت تحقق، نه تنها سودآوری بانکها را کاهش می‌دهد، بلکه ثبات کل نظام مالی را تهدید می‌کند. مطالعات نشان می‌دهد که بخش عمده دارایی‌های بانک‌ها را مطالبات تشکیل می‌دهد و شکست در مدیریت این دارایی‌ها می‌تواند به کاهش حقوق صاحبان سهام و حتی ورشکستگی بینجامد (داس^۱، ۲۰۱۹). در پاسخ به این چالش، کمیته بازل با ارائه چارچوبهای نظارتی، تحولی اساسی در مدیریت ریسک اعتباری ایجاد کرد. توافقنامه بازل II در سالهای آغازین قرن ۲۱، با تأکید بر «حساسیت به ریسک»، الزامات سرمایه‌ای بانک‌ها را از حالت ثابت و یکسان خارج کرد و آن را به رتبه‌بندی اعتباری وام‌گیرندگان و پرتفوی اعتباری بانک‌ها وابسته ساخت. این توافقنامه، بانک‌ها را ملزم کرد تا از دو روش اصلی برای ارزیابی ریسک استفاده کنند: استفاده از مؤسسات رتبه‌بندی اعتباری یا توسعه مدل‌های داخلی مبتنی بر داده‌های تاریخی. هدف این بود که سرمایه نگهداری شده توسط بانک‌ها، نه تنها متناسب با حجم فعالیت‌ها، بلکه متناسب با سطح ریسک هر وام باشد (لاندو^۲، ۲۰۰۹).

اما چگونه می‌توان ریسک اعتباری را به صورت عملیاتی کاهش داد؟ یکی از کارآمدترین ابزارها، سیستم‌های امتیازدهی اعتباری است که با تحلیل عوامل کیفی و کمی مانند سابقه مالی مشتری، درآمد، نسبت بدهی به دارایی، و ثبات شغلی، احتمال نکول را پیش‌بینی می‌کند (جیحونی‌پور و همکاران، ۱۴۰۳). این سیستم‌ها با تبدیل ریسک به یک متغیر کمی، به بانک‌ها اجازه می‌دهند تا

¹ Das

² Lando

مشتریان پریسک را شناسایی کرده و نرخ سود وام‌ها را متناسب با سطح ریسک تعیین کنند. پژوهش‌ها حاکی از آن است که استفاده از این روش‌ها تا ۳۰ درصد از هزینه‌های ناشی از مطالبات معوقه می‌کاهد (توماس^۱ و همکاران، ۲۰۱۳).

با این حال، در جهان امروز که بانک‌ها با چالش‌هایی مانند بین‌المللی شدن فعالیت‌ها، نوآوری‌های مالی پیچیده، و بحران‌های غیرمنتظره روبه‌رو هستند، مدیریت ریسک اعتباری نیازمند رویکردی پویاتر است. بحران مالی ۲۰۰۸ نمونه بارزی بود که نشان داد حتی مدل‌های پیشرفته نیز در صورت بی‌توجهی به عوامل کلان اقتصادی و «ریسک سیستماتیک» می‌توانند شکست بخورند. از این رو، بانک‌ها امروزه نه تنها بر رتبه‌بندی فردی وام‌گیرندگان تمرکز می‌کنند، بلکه با تحلیل روندهای اقتصادی، سیاست‌های پولی، و حتی تحولات ژئوپلیتیک، سعی در پیش‌بینی ریسک‌های نوظهور دارند (ندری و محرابی، ۱۳۹۷).

مدیریت ریسک اعتباری را باید فرایندی مستمر و چندبعدی دانست که ترکیبی از مقررات هوشمند (مانند بازل II)، فناوری‌های تحلیلی (مانند هوش مصنوعی در امتیازدهی)، و الگوهای نوین مالی را می‌طلبد. موفقیت در این حوزه، علاوه بر حفظ ثبات و پایداری مالی بانک‌ها، به جذب سرمایه‌گذاران، کاهش هزینه‌های تأمین مالی، و تقویت نقش بانک‌ها به عنوان نهادهای پیشران توسعه پایدار می‌انجامد.

رتبه‌بندی اعتباری مشتریان به عنوان یکی از ابزارهای کلیدی مدیریت ریسک اعتباری، با استفاده از روش‌های متنوعی از جمله الگوریتم‌های ژنتیک، ماشین یادگیری، روش‌های بیزی، تحلیل عاملی، و روش‌های هیبریدی انجام می‌شود. هر یک از این روش‌ها با مزایا و محدودیت‌های خاص خود، نیازمند انتخاب هوشمندانه مبتنی بر شرایط سازمانی و ماهیت داده‌ها هستند. در سال‌های اخیر، یادگیری عمیق به عنوان زیرمجموعه‌ای از هوش مصنوعی، با استفاده از شبکه‌های عصبی مصنوعی عمیق، تحولی در تحلیل داده‌های پیچیده و غیرخطی ایجاد کرده است. این روش با استخراج خودکار ویژگی‌های ارزشمند از داده‌های ورودی، امکان پیش‌بینی دقیق‌تر ریسک اعتباری را فراهم می‌کند و نیاز به تعریف دستی متغیرها را کاهش می‌دهد (گونارسون^۲ و همکاران، ۲۰۲۱). شبکه‌های عصبی عمیق بازگشتی^۳ (RNN) و شبکه‌های حافظه کوتاه - بلندمدت^۴ (LSTM) به عنوان نمونه‌هایی پیشرفته از معماری‌های یادگیری عمیق، توانایی منحصربه‌فردی در پردازش داده‌های دنباله‌ای و زمانی دارند. RNN با حفظ وابستگی‌های زمانی بین داده‌ها، امکان مدل‌سازی الگوهای پویا مانند رفتار مالی مشتریان در طول زمان را فراهم می‌کند. با این حال، مشکل فراموشی اطلاعات بلندمدت در RNN منجر به توسعه LSTM شد که با استفاده از واحدهای دروازه‌ای (گیت^۵ها)، امکان ذخیره و بازیابی اطلاعات حیاتی در بازه‌های زمانی طولانی‌تر را دارد. این قابلیت، LSTM را به ابزاری کارآمد در رتبه‌بندی اعتباری تبدیل کرده است، به ویژه زمانی که وابستگی‌های زمانی پنهان در داده‌ها (مانند سابقه پرداخت‌های مشتری) نقش کلیدی در پیش‌بینی ریسک ایفا می‌کنند (دو و شو^۶، ۲۰۲۲).

اگرچه مدل‌های یادگیری عمیق به تنهایی می‌توانند دقت بالایی در برخی مجموعه‌داده‌ها نشان دهند، اما وابستگی به ساختار داده و حساسیت به عدم تعادل کلاس‌ها (مانند داده‌های نامتوازن ریسک اعتباری) از چالش‌های اصلی آنهاست. برای مثال، یک کلاسیفایر مبتنی بر LSTM ممکن است در داده‌های متوازن عملکردی عالی داشته باشد، اما در داده‌های نامتوازن (که نمونه‌های نکول کمتر از مشتریان سالم هستند) به سمت کلاس اکثریت سوگیری کند. برای حل این مشکل، یادگیری گروهی^۷ به عنوان راهکاری مؤثر

¹ Thomas

² Gunnarsson

³ Recurrent Neural Network

⁴ Long Short-Term Memory

⁵ Gate

⁶ Du & Shu

⁷ Ensemble Learning

پیشنهاد شده است. در این روش، ترکیبی از چندین مدل پایه مانند LSTM، شبکه‌های کانولوشنی، یا درخت تصمیم برای بهبود دقت و کاهش واریانس خطا استفاده می‌شوند (آلاراج^۱ و همکاران، ۲۰۲۲).

در این پژوهش، با هدف رتبه‌بندی اعتباری مشتریان یک بانک ایرانی، از یادگیری عمیق گروهی حساس به هزینه استفاده شده است که به صورت یکپارچه با الگوریتم ژنتیک (GA) هیپنه‌سازی می‌شود. این چارچوب پیشنهادی دو مرحله اصلی دارد:

۱. انتخابی ویژگی بهینه: با استفاده از GA، متغیرهای کلیدی از داده‌های خام (مانند سن، درآمد، سابقه اعتباری، و نسبت بدهی به دارایی) استخراج می‌شوند تا ابعاد داده کاهش یابد و نویز حذف شود.

۲. ترکیب وزنی مدل‌ها: مدل‌های پایه (شامل LSTM، AdaBoost، Bagging و جنگل تصادفی^۲ (RF)) با وزن‌های بهینه‌شده توسط GA ترکیب می‌شوند تا یک خروجی گروهی با دقت بالاتر تولید شود.

برای ارزیابی مدل، از دو مجموعه داده بنچمارک UCI (داده‌های متوازن استرالیا و نامتوازن آلمان) و همچنین داده‌های واقعی مشتریان یک بانک ایرانی استفاده شده است. به منظور پیاده‌سازی مدل، از محیط پایتون و کتابخانه‌های TensorFlow، Keras، و Scikit-learn استفاده می‌شود.

۱. ادبیات و پیشینه تحقیق

در دنیای مدیریت مالی و بانکداری، ارزیابی دقیق اعتبار مشتریان به عنوان یکی از وظایف بنیادین و حیاتی موسسات مالی و اعتباری مطرح است؛ فرآیند رتبه‌بندی اعتباری با تحلیل دقیق عوامل ریسک و احتمال بازپرداخت بدهی‌ها، به بانک‌ها و موسسات اعتباری کمک می‌کند تا با کاهش ریسک‌های ناشی از اعطای تسهیلات، بتوانند استراتژی‌های سودآوری و رشد پایداری را در فعالیت‌های خود به کار گیرند. این ارزیابی، که بر پایه بررسی داده‌های گذشته و شرایط مالی و اقتصادی مشتریان انجام می‌شود، امکان شناسایی الگوهای رفتاری و پیش‌بینی دقیق‌تر نسبت به توانایی بازپرداخت بدهی‌ها را فراهم می‌آورد و به عنوان ابزاری کلیدی در مدیریت ریسک اعتباری مطرح است. ریسک اعتباری، به معنای احتمال عدم توانایی مشتریان در انجام تعهدات مالی خود، یکی از چالش‌های اساسی در حوزه مالی محسوب می‌شود. همانطور که باتاچاریا^۳ و همکاران (۲۰۲۳) بیان کرده‌اند، این ریسک می‌تواند تأثیرات منفی گسترده‌ای بر پایداری سیستم‌های بانکی داشته باشد؛ به همین دلیل، موسسات مالی از ابزارها و روش‌های متعددی مانند ارزیابی اعتبار، تنظیم سیاست‌های محدودسازی ریسک، تنوع‌بخشی به سبد وام‌ها و استفاده از بیمه‌های اعتباری بهره می‌گیرند. گزارش‌های کمیته بال (بلکی و روتوفسکی^۴، ۲۰۱۳) نیز به نقش مهم اعطای تسهیلات به عنوان منبع اصلی ریسک اعتباری اشاره دارند؛ این تسهیلات در صورت نوسان شرایط بازپرداخت مشتریان، می‌توانند باعث تغییرات عمده در ارزش اوراق و ابزارهای مشتقه شوند که این امر مستقیماً بر سلامت سیستم بانکی تأثیرگذار است.

با پیشرفت فناوری‌های نوین اطلاعاتی و سیستم‌های رایانه‌ای، روند رتبه‌بندی اعتباری دستخوش تحولاتی چشمگیر شده است. در گذشته که سیستم‌های ارزیابی متنوع و پراکنده موجب ایجاد پیچیدگی در امتیازدهی می‌شد، امروزه با بهره‌گیری از تحلیل‌های پیشرفته، داده‌های بزرگ و الگوریتم‌های هوشمند، امکان ایجاد مدل‌های پیش‌بینی دقیق‌تر فراهم آمده است. این تحولات موجب شده تا علاوه بر ارزیابی وضعیت کنونی مشتریان، توانایی پیش‌بینی رفتارهای آینده و شناسایی زود هنگام ریسک‌های احتمالی نیز بهبود یابد. به عبارتی دیگر، امروزه علاوه بر بررسی معیارهایی نظیر تاریخچه پرداخت، سوابق اعتباری، وضعیت دارایی‌ها و بدهی‌ها و درآمدهای ثابت، عوامل دیگری مانند ثبات شغلی، الگوهای مصرفی و حتی شاخص‌های اقتصادی کلان مورد توجه قرار می‌گیرند

¹ Ala'raj

² Random Forest

³ Bhattacharya

⁴ Bielecki & Rutkowski

(کان^۱ و همکاران، ۲۰۲۴). مؤسسات مالی و بانک‌ها از مدل‌های امتیازدهی به دو صورت بهره‌مند می‌شوند: از یک سو رتبه‌بندی خارجی که توسط سازمان‌های معتبر بین‌المللی مانند استاندارد اند پورز، فیچ و مودیز ارائه می‌شود و از سوی دیگر رتبه‌بندی داخلی که بر اساس سیستم‌های اختصاصی و سیاست‌های خاص هر بانک تنظیم می‌گردد. در این میان، موسسه استاندارد اند پورز رتبه‌بندی اعتباری را به عنوان اظهار نظر درباره اعتبار یک بدهکار بر مبنای عوامل ریسک تعریف کرده و از دیدگاه موسسه مودیز، این امتیازدهی بیانگر توانایی آینده بدهکار در بازپرداخت به موقع اصل و سود است (مون و استوسکی^۲، ۱۹۹۳؛ اونگ^۳ و همکاران، ۲۰۰۵).

از سویی دیگر، مدیریت ریسک اعتباری نه تنها به عنوان ابزاری جهت پیش‌بینی احتمال نکول مشتریان به کار گرفته می‌شود، بلکه در تعیین سیاست‌های کلان مدیریتی نیز نقش مؤثری دارد. احمد و راجالکسمی^۴ (۲۰۱۹) سه دسته سیاست کلان در این زمینه معرفی کرده‌اند: سیاست‌های محدودسازی یا کاهش ریسک اعتباری که شامل تمرکز بر اعطای تسهیلات به مشتریان منتخب است؛ سیاست‌های طبقه‌بندی دارایی‌ها و ارزیابی‌های مستمر که به کمک آن‌ها توانایی وصول پرتفوی وام‌ها سنجیده می‌شود؛ و سیاست‌های کاهش زیان که از طریق اقدامات محتاطانه و اعطای اختیارات مدیریتی مناسب، تلاش در حذف یا کاهش خسارات احتمالی دارند. این رویکردها به همراه نظارت دقیق مقامات نظارتی بر سرمایه و اعتبار بانک‌ها، چارچوبی مستحکم برای مقابله با نوسانات و بحران‌های احتمالی فراهم می‌کنند (نائیلی و لاهیرچی^۵، ۲۰۲۰).

توسعه سیستم‌های رتبه‌بندی اعتباری از دهه ۱۹۵۰ میلادی آغاز شده و با گذر زمان به واسطه پیشرفت‌های فناوری و دسترسی به داده‌های دقیق‌تر، توانسته‌اند نقش اساسی در تصمیم‌گیری‌های اعتباری داشته باشند. در این بین، استفاده از داده‌های بنچمارک و به کارگیری الگوریتم‌های پیشرفته به بهبود دقت پیش‌بینی‌ها کمک شایانی نموده است؛ هرچند که همچنان هیچ مدلی قادر به پیش‌بینی کامل و بدون اشتباه رفتار مشتریان در شرایط متغیر اقتصادی نیست. بنابراین، ترکیب تحلیل‌های آماری با تجربیات مدیریتی و نظارت‌های پیوسته از الزامات اساسی در مدیریت ریسک اعتباری محسوب می‌شود. این رویکرد جامع و چندبعدی در نهایت به حفظ پایداری بانک‌ها و تأمین سلامت اقتصاد کلان کمک می‌کند، چرا که با کاهش ریسک‌های ناشی از عدم بازپرداخت، زمینه ایجاد اعتماد در سیستم مالی و افزایش سرمایه‌گذاری‌های اقتصادی فراهم می‌آید (آدی^۶ و همکاران، ۲۰۲۴).

فرآیند رتبه‌بندی اعتباری به عنوان یکی از ارکان اساسی در تحلیل ریسک اعتباری مشتریان، در طول سالیان متمادی دستخوش تحول و تکامل عمیقی شده است. در دوران اولیه، بانک‌ها برای ارزیابی اعتبار مشتریان از رویکردهای سنتی و تجربی بهره می‌گرفتند؛ به عبارت دیگر، تصمیم‌گیری بر اساس روابط شخصی و اعتماد متقابل از اصول بنیادین در تعیین اعتبار محسوب می‌شد. با رشد صنعت بانکی و افزایش پیچیدگی معاملات مالی، ضرورت به کارگیری روش‌های مدلسازی دقیق‌تر و علمی‌تر بیش از پیش احساس گردید؛ به همین منظور، در این دوره برخی مدل‌های آماری مبتنی بر اصول ریاضی و احتمالات معرفی شدند (جوشی^۷، ۲۰۲۵). ورود فناوری‌های نوین محاسباتی و افزایش توان پردازشی کامپیوترها موج جدیدی از روش‌های رتبه‌بندی اعتباری را به وجود آورد. در این راستا، ابزارهایی مانند شبکه‌های عصبی مصنوعی و درخت‌های تصمیم‌گیری مطرح شدند که توانستند با ارائه تحلیل‌های دقیق‌تر، جایگزین روش‌های تجربی گردند. از دهه ۱۹۹۰ به بعد، کاربرد روش‌های یادگیری ماشین در رتبه‌بندی اعتباری آغاز شد؛

¹ Cahn

² Moon & Stotsky

³ Ong, Huang & Tzeng

⁴ Ahmed & Rajaleximi

⁵ Naili & Lahrichi

⁶ Addy

⁷ Joshi

الگوریتم‌هایی نظیر SVM و انواع شبکه‌های عصبی به عنوان گام‌های نخست در این مسیر به کار گرفته شدند. ورود به دهه ۲۰۰۰ و ظهور روش‌های یادگیری عمیق، امکان استفاده از شبکه‌های عصبی عمیق مانند LSTM را فراهم ساخت؛ این شبکه‌ها قادر به مدل‌سازی و استخراج الگوهای پیچیده از داده‌های بزرگ و متنوع هستند (موفو و موکوسرا^۱، ۲۰۱۴).

امروزه، تکنیک‌های یادگیری عمیق به ویژه شبکه‌های عصبی بازگشتی مانند LSTM و سایر روش‌های مدل‌سازی پیشرفته، به عنوان ابزارهای قدرتمندی در رتبه‌بندی اعتباری شناخته می‌شوند. این روش‌ها با دقت بالا در شناسایی الگوهای نهفته و پیچیده، نقش اساسی در بهبود ارزیابی اعتبار مشتریان و مدیریت ریسک اعتباری ایفا می‌کنند. از سوی دیگر، رویکردهای فراابتکاری که مبتنی بر الگوریتم‌های تکاملی، ژنتیک، جستجوی همزمان و الگوریتم‌های شبه تصادفی هستند، با ترکیب چندین مدل و الگوریتم در جستجوی پاسخ‌های بهینه، توانسته‌اند دقت و کارایی فرآیند رتبه‌بندی را افزایش دهند. مزایای این روش‌ها شامل دقت بالاتر، تطبیق بهتر با داده‌های پیچیده و متنوع، مقاومت در برابر نویز و بهینه‌سازی مؤثر پارامترها می‌باشد؛ به عبارتی، بهره‌گیری از این رویکردها به بهبود تصمیم‌گیری‌های مرتبط با ریسک اعتباری منجر می‌شود (المفتی^۲ و همکاران، ۲۰۲۳).

در طول چند دهه گذشته، پژوهش‌های متعددی در حوزه رتبه‌بندی اعتباری با هدف بهبود دقت پیش‌بینی ریسک اعتباری مشتریان انجام شده است. در سال ۱۳۸۹، اخباری و مخاطب‌رفیعی با به کارگیری مدل عصبی - فازی (ANFIS) توانستند با دستیابی به دقت طبقه‌بندی «۶۹/۳۶ درصد»، گامی ابتدایی در جهت استفاده از روش‌های ترکیبی در تحلیل ریسک بردارند (اخباری و مخاطب‌رفیعی، ۱۳۸۹). به دنبال این مطالعه، در سال ۱۳۹۲، دادمحمدی و احمدی از شبکه عصبی با تابع محرک شعاعی استفاده کردند که نتایج نشان داد این روش قادر به پیش‌بینی دقیق رفتار مشتریان می‌باشد (دادمحمدی و احمدی، ۱۳۹۲). در همان سال، اسراری با مقایسه رگرسیون لاجیت، شبکه عصبی و الگوریتم ژنتیک به دست آورد که این سه روش به‌طور نسبی از دقت مشابهی در پیش‌بینی ریسک اعتباری مشتریان حقیقی برخوردارند (اسراری، ۱۳۹۲). در ادامه، مهدوی و حری در سال ۱۳۹۴ الگوریتم فراابتکاری و هیبریدی چند معیاره مبتنی بر ترکیب شبکه عصبی فازی و کلونی مورچگان را ارائه دادند که سیستم پیشنهادی در «۸۹/۶۷ درصد» از موارد قادر به ارائه تخمین صحیح نسبت به رتبه اعتباری مشتریان بود (مهدوی و حری، ۱۳۹۴). سال ۱۳۹۵ شاهد مطالعه‌ای از گل‌محمدی بود که از ترکیب الگوریتم ژنتیک و رگرسیون لجستیک بهره برد و نتایج نشان‌دهنده برتری الگوریتم ژنتیک در این ترکیب گردید (گل‌محمدی، ۱۳۹۵). همچنین، کوچه‌باغی و رجبی بهجت در سال ۱۳۹۶ الگوریتم فراابتکاری جستجوی گرانشی باینری را معرفی کردند؛ نتایج این مطالعه از منظر معیار F-Score، نشان از توان بالای این الگوریتم در فرایند طبقه‌بندی داشت (کوچه‌باغی و رجبی بهجت، ۱۳۹۶). پاک‌بین و پویانفر در سال ۱۳۹۷ تکنیک طبقه‌بندی ترکیبی پویا و احتمال نرم (DECSP) را پیشنهاد کردند؛ یافته‌های این تحقیق حاکی از آن بود که روش DECSP نسبت به الگوریتم‌های کلاسیکی مانند KNN، ANN، درخت تصمیم، SVM و AdaBoost عملکرد به مراتب بهتری دارد (پاک‌بین و پویانفر، ۱۳۹۷). در سال ۱۳۹۸، نظرآقایی و همکاران با به کارگیری رویکرد یادگیری گروهی از طریق ترکیب شبکه‌های عصبی، درخت تصمیم فازی و بگینگ، به اهمیت عوامل درآمد و تراکنش‌های مالی در تعیین ریسک اعتباری پی بردند و همچنین نشان دادند استفاده از درخت تصمیم فازی همراه با بگینگ دقت طبقه‌بندی را افزایش می‌دهد (نظرآقایی و همکاران، ۱۳۹۸). همان سال، حسامی با استفاده از روش یادگیری عمیق به این نتیجه رسید که این رویکرد می‌تواند به کاهش ریسک عدم پرداخت بدهی مشتریان منجر شود (حسامی، ۱۳۹۸).

با گذر زمان، کاربرد روش‌های پیشرفته‌تر همچون یادگیری گروهی و بهبود یافته نیز مورد توجه قرار گرفت؛ ابتیاع و همکاران در سال ۱۴۰۰ با استفاده از یادگیری گروهی مبتنی بر ماشین بردار پشتیبان بر داده‌های بانک پاسارگاد ثابت کردند که این روش از روش‌های معمولی SVM و جنگل تصادفی برتری دارد (ابتیاع و همکاران، ۱۴۰۰). در سال ۱۴۰۲، خانجانی و همکاران به کاربرد

¹ Mpofu & Mukosera

² Almufti

گسترده هوش مصنوعی، به ویژه روش‌های یادگیری عمیق، در بهبود دقت و کیفیت تصمیم‌گیری مدل‌های رتبه‌بندی اعتباری پرداختند و نشان دادند این روش‌ها نسبت به روش‌های سنتی یادگیری ماشین عملکرد بهتری دارند (خانجانی و همکاران، ۱۴۰۲). از سوی دیگر، در مقطع زمانی بعدی، مطالعاتی نیز به استفاده از تکنیک‌های یادگیری جمعی پرداخته‌اند. به عنوان مثال، آبلان و مانتاس در سال ۲۰۱۴ با به کارگیری طرح Bagging در چند مدل درخت تصمیم‌گیری به افزایش دقت طبقه‌بندی در رتبه‌بندی اعتباری دست یافتند (آبلان و مانتاس^۱، ۲۰۱۴). ژوانگ^۲ و همکاران در سال ۲۰۱۵ روش مبتنی بر شبکه بیزی و اطلاعات متقابل (BNMI) را پیشنهاد کردند که با اندازه‌گیری وابستگی متغیرهای تصادفی، توانستند کارایی طبقه‌بندی را بهبود بخشند (ژوانگ و همکاران، ۲۰۱۵).

گلشنی، باقرزاده و داودی در همان سال با به کارگیری ترکیب تحلیل پوششی داده‌ها و تحلیل افتراقی (DEA-DA) اثبات کردند که روش پیشنهادی قادر به دسته‌بندی با دقت بالا مشتریان دریافت‌کننده وام در بانک‌های ایرانی می‌باشد (گلشنی، باقرزاده و داودی، ۲۰۱۶). در سال ۲۰۱۷، مطالعاتی نیز به مقایسه میان روش‌های مختلف پرداختند؛ آتیگری، پای و پای نشان دادند که در مقایسه بین رگرسیون لجستیک و شبکه عصبی، روش رگرسیون لجستیک عملکرد بهتری از خود ارائه می‌دهد (آتیگری^۳ و همکاران، ۲۰۱۷). در همین سال، التر و یاسین^۴ با مقایسه تجزیه و تحلیل خطی افتراقی (LDA)، شبکه عصبی چندلایه پرسپترون (MLP) و درخت تصمیم‌گیری CART به این نتیجه رسیدند که مدل MLP بالاترین دقت (ACC) و کمترین میزان خطا را دارا می‌باشد (التر و یاسین، ۲۰۱۷). همچنین، ستورینسو و هالیم^۵ با بهینه‌سازی روش رگرسیون لجستیک با الگوریتم Nelder-Mead نشان دادند که این روش نسبت به رگرسیون لجستیک کلاسیک کارایی بهتری دارد (ستورینسو و هالیم، ۲۰۱۷). دومیتروسکو^۶ در سال ۲۰۱۸ روش ترکیبی رگرسیون لجستیک و درخت تصمیم غیرخطی را معرفی نمود و نتایج حاصل نشان دادند که درخت تصمیم غیرخطی نسبت به رگرسیون لجستیک عملکرد بسیار بهتری در رتبه‌بندی اعتباری دارد (دومیتروسکو، ۲۰۱۸). در سال ۲۰۱۹، عبدو^۷ و همکاران با مقایسه تحلیل افتراقی، رگرسیون لجستیک، شبکه عصبی چند لایه رو به جلو و شبکه عصبی احتمالی دریافتند که روش‌های شبکه عصبی به‌طور کلی عملکرد بهتری از دو روش دیگر دارند و در این میان شبکه عصبی احتمالی بهترین نتایج را ارائه می‌دهد (عبدو و همکاران، ۲۰۱۹).

در سال‌های اخیر، پژوهش‌ها به سمت استفاده از معماری‌های پیشرفته یادگیری عمیق متمایل شده‌اند. ستاری مالکی و همکاران در سال ۲۰۲۱ با بهره‌گیری از LSTM Autoencoder نشان دادند که این مدل در انتخاب ویژگی و دسته‌بندی درست مشتریان دقت بالایی از خود دارد (ستاری مالکی و همکاران، ۲۰۲۱). همچنین، دو و شو در سال ۲۰۲۲ با ترکیب یادگیری عمیق RNN و الگوریتم بهینه‌سازی Bionic ثابت کردند که الگوریتم پیشنهادی نسبت به روش‌های مرسوم یادگیری ماشین و ترکیب‌های مختلف آن عملکرد بهتری دارد (دو و شو، ۲۰۲۲). در سال ۲۰۲۳، وانگ^۸ و همکاران از طریق یادگیری تقویتی عمیق مبتنی بر تکرار تجربه اولویت‌دار طبقه‌ای متوازن (DQN-BSPER) نشان دادند که مدل پیشنهادی قادر است از چهار مدل معیار DRL و هفت مدل طبقه‌بندی سنتی بهتر عمل کند (وانگ و همکاران، ۲۰۲۳). ژانگ^۹ و همکاران نیز در همان سال یک مدل امتیازدهی اعتباری گروهی بر مبنای رگرسیون

¹ Abellán & Mantas

² Zhuang

³ Attigeri

⁴ Eletter & Yaseen

⁵ Sutrisno & Halim

⁶ Dumitrescu

⁷ Abdou

⁸ Wang

⁹ Zhang

لجستیک با اثرات تعادلی و وزن دهی ناهمگن معرفی کردند که نتایج آن در مقایسه با ده مدل نماینده در شش مجموعه داده عمومی، قدرت تشخیص نمونه‌های پیش فرض و توانایی تعمیم بالاتری را نشان داد (ژانگ و همکاران، ۲۰۲۳). به علاوه، خلیلی و رستگار در سال ۲۰۲۳ مدل بهینه حساس به هزینه ترکیبی را با تلفیق مدل‌های DT، KNN، AdaBoost، SVM و شبکه عصبی احتمالاتی PNN ارائه کردند؛ نتایج نشان داد که روش پیشنهادی در هر دو شرایط داده متوازن و نامتوازن دقت بالایی از خود نشان می‌دهد (خلیلی و رستگار، ۲۰۲۳).

این مرور ادبی نشان می‌دهد که طی سال‌ها، پژوهشگران با بهره‌گیری از رویکردهای مختلف از مدل‌های سنتی آماری گرفته تا تکنیک‌های پیشرفته یادگیری عمیق و تقویتی، توانسته‌اند به بهبود دقت رتبه‌بندی اعتباری دست یابند. این پیشرفت‌ها نشان‌دهنده تمایل روزافزون به استفاده از هوش مصنوعی و روش‌های فراابتکاری در جهت مدیریت ریسک اعتباری و بهبود تصمیم‌گیری‌های مالی است که می‌تواند زمینه‌ساز توسعه سیستم‌های بانکی پربازده و مقاوم در برابر ریسک‌های ناشی از عدم پرداخت بدهی‌ها گردد.

۲. روش‌شناسی تحقیق

تحقیق حاضر از نظر هدف کاربردی و از نظر روش جز تحقیقات توصیفی است. داده‌های مورد استفاده در تحقیق نیز داده‌های مالی و اطلاعات دموگرافی اشخاص حقیقی یا حقوقی وام‌گیرنده از بانک‌ها می‌باشند. به منظور پیاده‌سازی مدل نیز از نرم‌افزار Python استفاده می‌شود.

۱.۲. داده‌ها

داده‌های مورد استفاده در این تحقیق شامل داده‌های مشتریان حقوقی یک بانک ایرانی و دو دیتاست بنچمارک آلمان و استرالیا هست. بررسی داده‌های سه کشور نشان می‌دهد که توزیع مشتریان خوش حساب و بدحساب از الگوهای متفاوتی پیروی می‌کند. در ایران، از مجموع ۲،۹۸۷ مشتری حقوقی، ۱،۷۲۱ مشتری (۵۷٫۶۲٪) خوش حساب و ۱،۲۶۶ مشتری (۴۲٫۳۸٪) بدحساب هستند که نسبت خوش حساب به بدحساب ۱٫۳۶ به ۱ است. در مقابل، آلمان با ۱،۰۰۰ مشتری، نرخ خوش حسابی بالاتری دارد: ۷۰۰ مشتری خوش حساب (۷۰٪) در برابر ۳۰۰ بدحساب (۳۰٪) که نسبت آن ۲٫۳۳ به ۱ می‌باشد. اما استرالیا وضعیت معکوسی دارد: از ۶۹۰ مشتری، ۳۰۷ مورد (۴۴٫۴۹٪) خوش حساب و ۳۸۳ مورد (۵۵٫۵۱٪) بدحساب هستند و نسبت خوش حساب به بدحساب ۰٫۸۰ به ۱ است (جدول ۱). در جدول ۲ متغیرهای اعتباری مشتریان حقوقی بانک ایرانی و در جدول ۳ متغیرهای کیفی و مقادیر آنها نشان داده شده است.

جدول ۱. جدول مقایسه‌ای توزیع مشتریان در دیتاست‌های مورد مطالعه

کشور	کل مشتریان	خوش حساب (تعداد)	خوش حساب (%)	بدحساب (تعداد)	بدحساب (%)	نسبت (خوش حساب: بدحساب)
ایران	۲،۹۸۷	۱،۷۲۱	۵۷٫۶۲٪	۱،۲۶۶	۴۲٫۳۸٪	۱٫۳۶:۱
آلمان	۱،۰۰۰	۷۰۰	۷۰٪	۳۰۰	۳۰٪	۲٫۳۳:۱
استرالیا	۶۹۰	۳۰۷	۴۴٫۴۹٪	۳۸۳	۵۵٫۵۱٪	۰٫۸۰:۱

منبع: نتایج تحقیق

جدول ۲. متغیرهای اعتباری مشتریان حقوقی بانک ایرانی

ردیف	متغیر	ردیف	متغیر
۱	وضعیت وام	۱۹	نسبت حساب دریافتی به فروش خالص
۲	میزان وام (ریال)	۲۰	نسبت حساب دریافتی به بدهی‌ها
۳	موجودی نقد در بانک (ریال)	۲۱	نسبت حساب پرداختی به فروش خالص
۴	نسبت بدهی به دارایی	۲۲	نسبت فروش به دارایی

نسبت حقوق صاحبان به دارایی	۲۳	نسبت فروش به دارایی ثابت
نسبت بدهی بلند مدت به دارایی	۲۴	نسبت سود خالص به دارایی‌ها
نسبت سود خالص به هزینه مالی	۲۵	نسبت سود خالص به فروش خالص
نسبت دارایی جاری به بدهی جاری	۲۶	نسبت سود خالص به دارایی ثابت
نسبت حساب دریافتی و موجودی نقد به بدهی جاری	۲۷	نسبت سود خالص به حقوق صاحبان
نسبت سرمایه در گردش به بدهی‌ها	۲۸	نسبت هزینه فروش به فروش خالص
نسبت دارایی جاری به بدهی‌ها	۲۹	اندازه بنگاه
نسبت بدهی جاری به دارایی‌ها	۳۰	وضعیت مالکیت ملک (اجاره، سرقفلی، دارای سند مالکیت غیر قابل ترهین)
نسبت موجودی نقد به دارایی‌ها	۳۱	ارتباط بین فعالیت و مدرک (۰ یا ۱)
نسبت موجودی نقد به فروش خالص	۳۲	حسن شهرت (عددی بین ۰ تا ۱)
نسبت سرمایه در گردش به فروش خالص	۳۳	نوع وثیقه (عددی بین ۰ تا ۱ برحسب نوع)
نسبت دارایی جاری به فروش خالص	۳۴	مدت بازپرداخت (سال)
نسبت موجودی نقد به بدهی جاری	۳۵	نرخ سود
نسبت سرمایه در گردش به بدهی‌های جاری	۱۸	

منبع: نتایج تحقیق

جدول ۳: متغیرهای کیفی و مقادیر آنها

مقدار	متغیر
(۰٫۲، ۰٫۴، ۰٫۶، ۰٫۸، ۱)	x_1 : وضعیت وام (تسویه شده، معوق، سررسید گذشته، تمدید مدت، استمهال شده)
(۰، ۰٫۵، ۱)	x_{30} : وضعیت مالکیت ملک (سرقفلی، دارای سند مالکیت غیر قابل ترهین، اجاره)
(۰، ۱)	x_{31} : ارتباط بین فعالیت و مدرک (مرتبط، غیرمرتبط)
(۰٫۲۵، ۰٫۵، ۰٫۷۵، ۱)	x_{32} : نوع وثیقه (ملک (غیرمنقول)، سپرده بلندمدت، اوراق مشارکت، چک و سایر)

منبع: نتایج تحقیق

۲.۲. روش پیشنهادی

در این تحقیق به منظور تجزیه و تحلیل داده‌ها از مدل یادگیری عمیق حساس به هزینه بهینه‌شده با استفاده از الگوریتم فرا ابتکاری GA استفاده شده است. همچنین از مدل LSTM و چند الگوریتم کلاسیفایر دیگر به منظور رتبه‌بندی اعتباری با مدل یادگیری گروهی استفاده می‌شود. فرایند بهینه‌سازی نیز بصورت یکپارچه و با در نظر گرفتن خطای دسته‌بندی^۱ (MC) به عنوان تابع هدف صورت می‌گیرد. شماتیک روش پیشنهادی بصورت شکل ۱ است و دارای ۴ مرحله است که ۳ مرحله آن بصورت یکپارچه انجام می‌شود:

۱. مرحله نرمالایز کردن داده‌ها
۲. مرحله انتخاب ویژگی
۳. مرحله کلاسه‌بندی
۴. مرحله بهینه‌سازی با الگوریتم GA

۱.۲.۲. مرحله اول: نرمالایز کردن داده‌ها

¹ Misclassification

در روش‌های خوشه‌بندی و دسته‌بندی، مقیاس کردن متغیرها اساسی‌ترین گام است؛ زیرا استفاده از مقادیر متغیرها بدون مقیاس، ممکن است منجر به تأثیر نامتعادل متغیرها با مقادیر بزرگ بر فرایند خوشه‌بندی و دسته‌بندی گردد. یکی از روش‌های رایج مقیاس کردن داده‌ها، نرمال‌سازی آنهاست. با اعمال نرمال‌سازی، مقادیر تمامی متغیرها به بازه‌ای معین مثل ۰ تا ۱ تبدیل می‌شوند. در این تحقیق، فرایند نرمال‌سازی کردن با استفاده از روش min-max انجام می‌شود که بصورت زیر است (سوکسامی^۱ و همکاران، ۲۰۲۲):


$$X = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (۱)$$

که در آن، X بردار مربوط به داده‌های اعتباری است.

۲،۲،۲. مرحله دوم: انتخاب ویژگی بهینه

در مسائل کلاسه‌بندی، ممکن است تمامی متغیرهای اعتباری در فرایند یادگیری الگوریتم‌های کلاسه‌بندی نقش مؤثری نداشته باشند و یا حتی تأثیر منفی بر این فرایند بگذارند. به منظور اجتناب از این موضوع، بایستی یک فرایند انتخاب ویژگی در نظر گرفته شود که توسط یک الگوریتم بهینه‌ساز مانند GA این امر میسر می‌شود. در این فرایند، متغیرهای اعتباری را که تحت عنوان ویژگی در نظر می‌گیریم، به دو حالت انتخاب شدن (۱) یا انتخاب نشدن (۰) توسط الگوریتم GA در نظر می‌گیریم. در نهایت آن دسته از ویژگی‌ها که مقدار ۱ برای آنها بدست آمده است، توسط الگوریتم GA انتخاب می‌شوند و سایر ویژگی‌ها کنار گذاشته می‌شوند.


¹ Suksamai



شکل ۱. شماتیک روش پیشنهادی

۳،۲،۲. مرحله سوم: کلاسه‌بندی بهینه

مرحله کلاسه‌بندی پیشنهادی در این پژوهش، یک کلاسه‌بندی حساس به هزینه و یادگیری جمعی است. حساس به هزینه یعنی الگوریتم‌ها در فرایند یادگیری به آن کلاسی که تعداد سمپل کمتری دارد (دیتای نامتوازن) وزن بیشتری نسبت به کلاس به تعداد سمپل بیشتر می‌دهند تا در فرایند یادگیری توازن برقرار شده و هر دو کلاس بخوبی توسط الگوریتم‌ها آموزش ببینند و نتایج حاصل از تست نیز برای هر دو کلاس مطلوب باشد. چنانچه این اتفاق نیفتد، خطای یادگیری کلاس به تعداد سمپل کمتر خیلی بیشتر از کلاس به تعداد سمپل زیاد می‌شود و در نتیجه الگوریتم بخوبی قادر به کلاسه‌بندی کلاس با تعداد سمپل کمتر نخواهد بود و مقدار این MC کلاس بیشتر خواهد شد. از سوی دیگر، یادگیری جمعی یعنی علاوه بر الگوریتم LSTM از الگوریتم‌های Bagging، Boosting و RF نیز استفاده خواهد شد و در نهایت بر اساس دقت یادگیری و کلاسه‌بندی الگوریتم‌ها، وزن بهینه برای هر یک از آنها تخصیص می‌یابد. شکل ۲ فرایند یادگیری جمعی پیشنهادی با الگوریتم‌های مذکور را نشان می‌دهد.



شکل ۲. فرایند یادگیری جمعی پیشنهادی (نتایج تحقیق)

یکی از گام‌های مهم در سنجش یک روش طبقه‌بندی، توزیع مناسب داده‌ها برای مدل‌سازی می‌باشد. در این پژوهش از روش اعتبارسنجی متقابل^۱ k-fold برای تقسیم‌بندی داده‌ها استفاده خواهد شد. بر این اساس، داده‌ها به ۵ بخش مساوی (k=5) بصورت تصادفی تقسیم می‌شوند و مدل طبقه‌بندی بر اساس این داده‌ها ساخته می‌شود. پس از طبقه‌بندی داده‌ها، از روش پیشنهادی برای هر یک از این طبقه‌ها استفاده خواهد شد و مقدار میانگین خطای دسته‌بندی طبقات به عنوان مقدار نهایی MC استفاده می‌شود.

۴.۲.۴. مرحله چهارم: بهینه‌سازی یکپارچه با الگوریتم GA

هایپرپارامترهای هر یک از الگوریتم‌ها، در کنار وزن بهینه تخصیصی به الگوریتم‌ها و فرایند انتخاب ویژگی بهینه توسط الگوریتم GA و بصورت یکپارچه انجام می‌شود. تابع برازندگی (Fitness) نیز میزان خطای کلاسه‌بندی (MC) در نظر گرفته می‌شود که برابر است با حاصل جمع تعداد خطای کلاس منفی (مشتري بدحساب) و کلاس مثبت (مشتري خوش حساب) بر کل تعداد سмпل‌ها در فرایند تست:

$$MC = \frac{FN + FP}{TP + TN + FP + FN} \quad (2)$$

که تعریف هر یک از متغیرهای فرمول فوق مطابق با جدول ۴ است.

جدول ۴. ماتریس درهم‌ریختگی

کلاس واقعی	کلاس پیش‌بینی شده	
	مشتریان بد	مشتریان خوب
مشتریان بد	منفی درست ^۳ (TN)	مثبت کاذب ^۲ (FP)
مشتریان خوب	منفی کاذب ^۵ (FN)	مثبت درست ^۴ (TP)

منبع: نتایج تحقیق

فلوچارت الگوریتم GA نیز بصورت شکل ۲ است. بنابراین مسئله بهینه پژوهش حاضر بصورت زیر بیان می‌شود:

$$Fitness = \min MC \quad (3)$$


¹ Cross-validation

² False positive

³ True negative

⁴ True positive

⁵ False negative



شکل ۲. فلوچارت الگوریتم GA.

۴.۲.۲. ارزیابی روش پیشنهادی

معیارهای مختلفی برای سنجش و ارزیابی روش های کلاسه بندی وجود دارد که در این پژوهش از هفت معیار مختلف استفاده

می شود که عبارتند از:

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4)$$

$$\text{ACC} = \frac{TN + TP}{TP+TN + FP + FN} \quad (5)$$

$$\text{Recall or Sensitivity} = \frac{TP}{TP+FN} \quad (6)$$

$$\text{F-Score} = (2 \times \text{Recall} \times \text{Precision}) / (\text{Recall} + \text{Precision}) \quad \text{Error! No text of specified style in }$$

(Vdocument.

$$\text{Error}_{\text{Type I}} = \frac{FP}{TN + FP} \quad (8)$$

$$\text{Error}_{\text{Type II}} = \frac{FN}{FN + TP} \quad (9)$$

$$\text{MC} = \frac{FN + FP}{TP+TN + FP + FN} \quad (10)$$

۳. یافته های تحقیق

در این بخش به بررسی نتایج حاصل از روش پیشنهادی پرداخته شده است. همانطور که در بخش پیشین بدان اشاره شد، روش پیشنهادی یک روش بهینه یکپارچه هست که با استفاده از تکنیک های مختلف و ویژگی به اعتبارسنجی مشتریان می پردازد. چهار روش مورد استفاده در این تحقیق عبارتند از روش های RF، AbaBoost، Bagging و LSTM. بنابراین هایپرپارامترهای این الگوریتم ها از طریق الگوریتم ژنتیک بهینه خواهد شد. جدول ۵ هایپرپارامترهای مدل را به همراه فضای جستجو (کران بالا (UB) و کران پایین (LB)) نشان داده است. همچنین در جدول ۶ پارامترهای الگوریتم ژنتیک نشان داده شده است. علاوه بر این، برای انتخاب ویژگی،

مقدار ۰ به منظور انتخاب نشدن ویژگی و مقدار ۱ به معنای انتخاب شدن ویژگی در نظر گرفته شده است. با در نظر گرفتن وزن الگوریتم‌ها، سه هاپیرپارامتر وزنی نیز که مقدار آنها بین ۰ و ۱ بوده و مجموع آنها برابر ۱ هست، لحاظ شده است. بنابراین، در مجموع با در نظر گرفتن ۱۱ هاپیرپارامتر نشان داده شده در جدول ۵ و سه پارامتر وزنی الگوریتم‌ها و n تعداد ویژگی دیتاست‌ها، تعداد هاپیرپارامترهای مسئله که از راه بهینه‌سازی با الگوریتم GA حاصل می‌شود، برابر با $n+14$ است.

جدول ۵. هاپیرپارامترهای الگوریتم‌ها

الگوریتم	پارامتر	LB	UB
AdaBoost	نرخ یادگیری	۰,۰۱	۱,۰
	تعداد تخمین گر‌ها	۵۰	۵۰۰
	ماکزیمم عمق	۱	۱۰
Bagging	تعداد تخمین گر‌ها	۵۰	۵۰۰
	ماکزیمم عمق	۱	۱۰
	نرخ ماکزیمم تعداد سمپل	۰,۰۱	۱,۰
RF	نرخ ماکزیمم تعداد ویژگی	۰,۰۱	۱,۰
	تعداد تخمین گر‌ها	۵۰	۵۰۰
	ماکزیمم عمق	۱	۱۰
	نرخ ماکزیمم تعداد سمپل	۰,۰۱	۱,۰
	نرخ ماکزیمم تعداد ویژگی	۰,۰۱	۱,۰
	تعداد لایه‌های پنهان	۱۰	۵۰
LSTM	نرخ dropout	۰,۰۱	۰,۵
	نرخ یادگیری	۰,۰۱	۱,۰
	تعداد epoch	۱۰	۱۰۰

منبع: نتایج تحقیق

جدول ۶. پارامترهای الگوریتم ژنتیک


پارامتر	مقدار
اندازه جمعیت	۳۰
نرخ جهش	۰,۲
نرخ ترکیب	۰,۸
عملگر انتخاب	Tournament selection
حداکثر تعداد نسل	۳۰
تلورانس	1e-5
معیار توقف	رسیدن به تلورانس مدنظر یا حداکثر تعداد نسل

منبع: نتایج تحقیق

همانطور که مشخص شد، دیتای مشتریان حقوقی بانک ایرانی به نسبت ۵۷٪ مشتری خوش حساب به ۴۲٪ مشتری بدحساب است و در نتیجه یک دیتای تقریباً متوازن محسوب می‌شود. فرآیندی همگرایی مدل پیشنهادی برای دیتای ایران در نسل ۱۹ به دست آمده (Error! Reference source not found. ۳) و نشان‌دهنده فضای جستجوی نسبتاً پیچیده برای پارامترهای مدل می‌باشد. نتایج به دست آمده از

دیتاست ایران نشان می‌دهد که الگوریتم‌های منفرد در این چارچوب دارای عملکرد قابل قبولی از نظر معیارهایی مانند دقت (ACC)، میزان صحت (Precision)، فراخوانی (Recall) و شاخص F1 هستند (جدول ۷ تا ۱۰). بر اساس نتایج به‌دست آمده از داده‌های ایران، عملکرد الگوریتم‌های منفرد در این چارچوب از نظر معیارهای ارزیابی نظیر دقت (Accuracy)، میزان صحت (Precision)، فراخوانی (Recall) و شاخص F1 قابل قبول بوده است. به‌طور مشخص، مدل AdaBoost دقتی در حدود ۰,۹۱۴، مدل Bagging دقتی برابر ۰,۹۲۷ و مدل‌های Random Forest و LSTM دقت‌هایی در بازه ۰,۹۱۴ تا ۰,۹۳۱ را به ثبت رسانده‌اند. با ترکیب خروجی‌های این الگوریتم‌ها و استفاده از وزن‌های بهینه‌شده شامل AdaBoost: 0.295، Bagging: 0.219، Random Forest: 0.188 و LSTM: 0.297، عملکرد کلی مدل ترکیبی اندکی بهبود یافته است. این مدل ترکیبی به میانگین دقتی معادل ۰,۹۳۴، میزان صحت ۰,۸۷۹، فراخوانی ۰,۸۹۸ و شاخص F1 برابر ۰,۸۸۸ دست یافته است. علاوه بر این، کاهش قابل توجهی در خطاهای نوع اول (False Positive) با میانگین ۰,۰۶۳ و خطاهای نوع دوم (False Negative) با میانگین ۰,۱۱۶ مشاهده شده و میزان کل خطای طبقه‌بندی به ۰,۰۶۶ رسیده است (جدول ۱۱).

مقادیر بهینه به‌دست آمده برای هر الگوریتم در جدول ۱۲ نشان داده شده است. هاپرپارامترهای بهینه برای هر الگوریتم نیز به‌خوبی با ویژگی‌های داده‌ها و نیازهای مسئله تطبیق داده شده‌اند. برای AdaBoost، نرخ یادگیری ۰,۱۴۹، تعداد تخمین‌گرها ۱۲۷ و حداکثر عمق ۶؛ برای Bagging، تعداد تخمین‌گرها ۲۷۴ و حداکثر عمق ۵؛ برای Random Forest، تعداد تخمین‌گرها ۲۳۸ و حداکثر عمق ۶؛ و برای LSTM، تعداد لایه‌های پنهان ۳۹، نرخ dropout برابر ۰,۱۸۸، نرخ یادگیری ۰,۲۸۹ و تعداد epoch برابر ۱۰۹ به‌عنوان مقادیر بهینه تعیین شده‌اند. این تنظیمات نشان‌دهنده انطباق مناسب مدل‌ها با داده‌ها و پیچیدگی‌های مسئله طبقه‌بندی است.



شکل ۳. نمودار همگرایی مدل پیشنهادی برای دیتای ایران (منبع: خروجی نرم افزار)

جدول ۷. عملکرد الگوریتم AdaBoost برای دیتای ایران

MC	E-Type II	E-Type I	F1-Score	Recall	Precision	ACC	Fold
0.086	0.090	0.094	0.933	0.936	0.930	0.914	1
0.074	0.095	0.095	0.924	0.924	0.923	0.926	2
0.086	0.095	0.124	0.915	0.926	0.904	0.914	3
0.098	0.090	0.095	0.935	0.936	0.934	0.902	4
0.084	0.154	0.095	0.911	0.898	0.925	0.916	5
0.086	0.105	0.101	0.924	0.924	0.923	0.914	Mean

منبع: نتایج تحقیق

جدول ۸. عملکرد الگوریتم Bagging برای دیتای ایران

MC	E-Type II	E-Type I	F1-Score	Recall	Precision	ACC	Fold
0.060	0.021	0.030	0.966	0.977	0.954	0.940	1
0.093	0.136	0.123	0.898	0.891	0.905	0.907	2
0.065	0.056	0.025	0.935	0.907	0.966	0.935	3
0.066	0.079	0.056	0.931	0.958	0.906	0.934	4
0.080	0.054	0.064	0.930	0.936	0.924	0.920	5
0.073	0.069	0.060	0.932	0.934	0.931	0.927	Mean

منبع: نتایج تحقیق

جدول ۹. عملکرد الگوریتم RF برای دیتای ایران

MC	E-Type II	E-Type I	F1-Score	Recall	Precision	ACC	Fold
0.067	0.022	0.029	0.970	0.970	0.969	0.933	1
0.055	0.013	0.061	0.956	0.990	0.924	0.945	2
0.070	0.134	0.038	0.946	0.957	0.935	0.930	3
0.075	0.021	0.081	0.945	0.977	0.915	0.925	4
0.081	0.030	0.068	0.943	0.961	0.925	0.919	5
0.069	0.044	0.055	0.952	0.971	0.934	0.931	Mean

منبع: نتایج تحقیق

جدول ۱۰. عملکرد الگوریتم LSTM برای دیتای ایران

MC	E-Type II	E-Type I	F1-Score	Recall	Precision	ACC	Fold
0.075	0.102	0.088	0.929	0.944	0.915	0.925	1
0.093	0.044	0.069	0.956	0.968	0.943	0.907	2
0.075	0.020	0.153	0.937	0.979	0.897	0.925	3
0.093	0.087	0.174	0.900	0.915	0.885	0.907	4
0.094	0.102	0.071	0.940	0.944	0.936	0.906	5
0.086	0.071	0.111	0.932	0.950	0.915	0.914	Mean

منبع: نتایج تحقیق

جدول ۱۱. عملکرد مدل ترکیبی برای دیتای ایران

MC	E-Type II	E-Type I	F1-Score	Recall	Precision	ACC	Fold
0.077	0.078	0.052	0.918	0.952	0.886	0.923	1
0.076	0.111	0.101	0.864	0.899	0.831	0.924	2
0.069	0.095	0.030	0.927	0.915	0.939	0.931	3

0.071	0.202	0.098	0.815	0.798	0.833	0.929	4
0.037	0.093	0.035	0.915	0.927	0.903	0.963	5

0.066	0.116	0.063	0.888	0.898	0.879	0.934	Mean
-------	-------	-------	-------	-------	-------	-------	------


منبع: نتایج تحقیق

جدول ۱۲. مقادیر بهینه های پارامترهای مدل برای دیتای ایران

مقدار بهینه	UB	LB	پارامتر	الگوریتم
۰,۱۴۹	۱,۰	۰,۰۱	نرخ یادگیری	AdaBoost
۱۲۷	۵۰۰	۵۰	تعداد تخمین گرها	
۶	۱۰	۱	ماکزیم عمق	
۲۷۴	۵۰۰	۵۰	تعداد تخمین گرها	Bagging
۵	۱۰	۱	ماکزیم عمق	
۰,۱۹۶	۱,۰	۰,۰۱	نرخ ماکزیمم تعداد سмпل	
۰,۲۴۵	۱,۰	۰,۰۱	نرخ ماکزیمم تعداد ویژگی	RF
۲۳۸	۵۰۰	۵۰	تعداد تخمین گرها	
۶	۱۰	۱	ماکزیم عمق	
۰,۴۳۲	۱,۰	۰,۰۱	نرخ ماکزیمم تعداد سмпل	LSTM
۰,۷۹۶	۱,۰	۰,۰۱	نرخ ماکزیمم تعداد ویژگی	
۳۹	۵۰	۱۰	تعداد لایه های پنهان	
۰,۱۸۸	۰,۵	۰,۰۱	نرخ dropout	وزن الگوریتم ها
۰,۲۸۹	۱,۰	۰,۰۱	نرخ یادگیری	
۱۰۹	۱۰۰	۱۰	تعداد epoch	
۰,۲۹۵	۱	۰	AbaBoost	Bagging
۰,۲۱۹	۱	۰	Bagging	
۰,۱۸۸	۱	۰	RF	
۰,۲۹۷	۱	۰	LSTM	

منبع: نتایج تحقیق

نمودار ROC الگوریتم های مدل رویکرد اول نیز در شکل ۴ نشان داده شده است. همانطور که در این شکل مشاهده می شود، مقدار ROC الگوریتم ها مقدار قابل توجه برابر ۰,۹۵ هست که نشان از دقت بالای آنها برای دیتای ایران دارد. همچنین مقدار ROC مدل ترکیبی بیشتر از مدل های مذکور هست و به مقدار ۰,۹۶ رسیده است که نشان می دهد، رویکرد ترکیبی پیشنهادی باعث بهبود دقت نهایی می شود.



شکل ۴. نمودار ROC مدل پیشنهادی برای دیتای ایران (خروجی نرم افزار)


	Loan Status	Loan Amount	Cash Balance in Bank	Debt to Asset Ratio	Equity to Asset Ratio	Long-term Debt to Asset Ratio	Net Profit to Financial Cost Ratio	Current Assets to Current Liabilities Ratio	Working Capital to Liabilities Ratio	Current Assets to Liabilities Ratio	Current Liabilities to Assets Ratio	Cash to Assets Ratio	Cash to Net Sales Ratio	Working Capital to Net Sales Ratio	Current Assets to Net Sales Ratio	Cash to Current Liabilities Ratio	Working Capital to Current Liabilities Ratio	Receivables to Net Sales Ratio	Receivables to Liabilities Ratio	Payables to Net Sales Ratio	Sales to Assets Ratio	Sales to Fixed Assets Ratio	Net Profit to Assets Ratio	Net Profit to Net Sales Ratio	Net Profit to Fixed Assets Ratio	Net Profit to Equity Ratio	Selling Expenses to Net Sales Ratio	Firm Size	Property Ownership Status	Relevance of Activity to Degree	Reputation	Collateral Type	Repayment Period	Interest Rate
Approach 1	1	1	0	1	1	1	0	0	1	0	0	1	0	0	0	0	0	1	0	1	1	0	0	0	0	0	1	1	0	0	1	1	0	0
Approach 2	1	1	1	1	0	1	0	1	1	1	0	1	0	0	1	0	1	0	1	1	0	0	1	0	1	0	1	1	0	0	1	0	1	1

شکل ۵. مقایسه ویژگی‌های بهینه انتخاب شده دو رویکرد پیشنهادی برای دیتای ایران (خروجی نرم افزار)


در انتخاب ویژگی‌های بهینه که در شکل ۵ نشان داده شده است، مشاهده می‌شود که ویژگی‌های ۱ (وضعیت وام)، ۲ (میزان وام)، ۴ (نسبت بدهی به دارایی)، ۵ (نسبت حقوق صاحبان به دارایی)، ۶ (نسبت بدهی بلند مدت به دارایی)، ۹ (نسبت حساب دریافتی و موجودی نقد به بدهی جاری)، ۱۲ (نسبت بدهی جاری به دارایی‌ها)، ۱۸ (نسبت سرمایه در گردش به بدهی‌های جاری)، ۲۰ (نسبت حساب دریافتی به بدهی‌ها)، ۲۱ (نسبت حساب پرداختنی به فروش خالص)، ۲۸ (نسبت هزینه فروش به فروش خالص)، ۲۹ (اندازه بنگاه)، ۳۲ (حسن شهرت) و ۳۳ (نوع وثیقه) به عنوان ویژگی‌های بهینه انتخاب شده‌اند.

به منظور اعتبارسنجی مدل پیشنهادی، از داده‌های بنچمارک استرالیا و آلمان استفاده شده است. نمودار همگرایی مدل پیشنهادی برای دیتای استرالیا و آلمان در شکل ۶ نشان داده شده است. همانطور که از این شکل مشخص است، الگوریتم برای دیتای استرالیا در نسل ۱۴ و برای دیتای آلمان در تکرار ۲۷ به همگرایی رسیده است که نشان‌دهنده فضای جستجوی پیچیده برای تنظیم پارامترهای مدل می‌باشد. نتایج برآورد مدل برای این دو دیتاست نیز به ترتیب در جدول ۱۳ و ۱۴ آورده شده است. مدل ترکیبی برای دیتای استرالیا دارای میانگین دقتی برابر ۰٫۹۰۲، Precision برابر ۰٫۸۷۹، Recall برابر ۰٫۸۹۸ و F1-Score برابر ۰٫۸۸۸ است. همچنین، کاهش قابل توجهی در خطاهای نوع I (False Positive) به میانگین ۰٫۰۶۳ و خطاهای نوع II (False Negative) به میانگین ۰٫۱۱۶ به همراه میزان کل خطای

طبقه‌بندی (MC) برابر با ۰,۰۹۸ مشاهده شده است. برای دیتای آلمان نیز منجر به دستیابی به میانگین دقت ۰,۸۴۳، Recall، Precision 0.902، F1-Score 0.910 و 0.918 شده است؛ همچنین، نرخ خطای نوع I و II به ترتیب به مقادیر ۰,۱۲۶ و ۰,۱۱۴ و MC برابر ۰,۱۵۷ کاهش یافته است.



(ب) دیتای آلمان



(الف) دیتای استرالیا

شکل ۶. نمودار همگرایی مدل پیشنهادی برای دیتای استرالیا و آلمان. (خروجی نرم افزار)
جدول ۱۳. عملکرد مدل ترکیبی برای دیتای استرالیا

MC	E-Type II	E-Type I	F1-Score	Recall	Precision	ACC	Fold
0.086	0.078	0.052	0.918	0.952	0.886	0.914	1
0.119	0.111	0.101	0.864	0.899	0.831	0.881	2
0.054	0.095	0.030	0.927	0.915	0.939	0.946	3
0.163	0.202	0.098	0.815	0.798	0.833	0.837	4
0.069	0.093	0.035	0.915	0.927	0.903	0.931	5
0.098	0.116	0.063	0.888	0.898	0.879	0.902	Mean


منبع: نتایج تحقیق

جدول ۱۴. عملکرد مدل ترکیبی برای دیتای آلمان


MC	E-Type II	E-Type I	F1-Score	Recall	Precision	ACC	Fold
0.164	0.171	0.167	0.889	0.899	0.880	0.836	1
0.195	0.143	0.121	0.892	0.887	0.897	0.805	2
0.155	0.104	0.131	0.905	0.916	0.895	0.845	3
0.140	0.089	0.127	0.912	0.931	0.893	0.860	4
0.130	0.064	0.085	0.950	0.956	0.945	0.870	5
0.157	0.114	0.126	0.910	0.918	0.902	0.843	Mean

منبع: نتایج تحقیق

نمودار ROC الگوریتم‌های مدل برای دیتاست استرالیا نیز در شکل ۷ نشان داده شده است. همانطور که در این شکل مشاهده می‌شود، مقدار ROC الگوریتم‌ها مقدار قابل توجه برابر ۰,۹۳ هست که نشان از دقت بالای آنها برای دیتای استرالیا دارد. همچنین مقدار ROC مدل ترکیبی بیشتر از مدل‌های مذکور هست و به مقدار ۰,۹۴ رسیده است که نشان می‌دهد، رویکرد ترکیبی پیشنهادی باعث بهبود دقت نهایی می‌شود. همچنین نمودار ROC دیتای آلمان (شکل ۸) نشان می‌دهد که الگوریتم‌های منفرد مقدار ROC بین ۰,۸۳ و ۰,۸۶ دارند و مدل ترکیبی به ROC برابر ۰,۸۹ دست یافته که دلالت بر دقت بسیار بالا و توان تفکیک قوی مدل‌ها در دیتای آلمان دارد.



شکل ۷. نمودار ROC مدل پیشنهادی برای دیتای استرالیا (خروجی نرم افزار)



شکل ۸. نمودار ROC مدل پیشنهادی با رویکرد اول برای دیتای آلمان (خروجی نرم افزار)

مقایسه نتایج مدل پیشنهادی با نتایج سایر محققین در جدول ۱۵ آورده شده است. همانطور که از این جدول مشاهده می‌شود، دقت مدل پیشنهادی به ویژه برای دیتای متوازن آلمان بیشتر از مدل‌های مشابه معرفی شده توسط سایر محققین برای حالت بدون دستکاری داده با استفاده از روش‌های نمونه‌برداری است. این امر نشان می‌دهد که مدل پیشنهادی توانایی بالایی برای حصول نتایج بسیار مناسب و با قوام برای دیتای پیچیده است که ذاتاً در دنیای واقعی، بانک‌ها با آن روبرو هستند.

جدول ۱۵. مقایسه نتایج مدل پیشنهاد با سایر منابع

دیتاست استرالیا	دیتاست آلمان	sampling	روش	دفرنس
0.909	0.794	×	NB-DT-QDA-TDNN-PNN (Majority Voting)	تریپاتی ^۱ و همکاران (۲۰۲۸)
0.909	0.794	×	NB-DT-QDA-TDNN-PNN (Weighted Voting)	

¹ Tripathi

0.908	0.805	×	NB-DT-QDA-TDNN-PNN (Layered Majority Voting)	
0.93	0.842	×	NB-DT-QDA-TDNN-PNN (Layered Weighted Voting)	
0.938	0.816	×	Stacking	خلیلی و رستگار (۲۰۲۳)
0.910	0.895	✓	XGBoost + SMOTE-ENN	آرولبا و سان (۲۰۲۴) ^۱
-	0.832	✓	Stacking + SMOTE	روفیک ^۲ و همکاران (۲۰۲۴)
0.902	0.843	×	Stacking	روش پیشنهادی

منبع: نتایج تحقیق

۴. بحث و نتیجه گیری

پژوهش حاضر با ارائه یک چارچوب ترکیبی مبتنی بر یادگیری عمیق حساس به هزینه و الگوریتم ژنتیک، گامی مؤثر در بهبود دقت پیشبینی ریسک اعتباری مشتریان حقوقی بانکها برداشت. نتایج نشان داد که رویکرد یکپارچه پیشنهادی، با بهینهسازی همزمان هایپرپارامترها، انتخاب ویژگیهای کلیدی (مانند «وضعیت وام»، «نسبت بدهی به دارایی»، و «حسن شهرت»)، و تلفیق وزنی الگوریتمهای مختلف (AdaBoost، Bagging، RF، و LSTM)، توانسته است خطای طبقه‌بندی (MC) را برای داده‌های ایران به ۶٫۶٪ و برای داده‌های بین‌المللی (آلمان و استرالیا) به ترتیب به ۱۵٫۷٪ و ۹٫۸٪ کاهش دهد. این بهبود عملکرد، ناشی از توانایی مدل در موازنه‌سازی تأثیر داده‌های نامتوازن و بهره‌گیری از نقاط قوت الگوریتم‌های متفاوت است. همچنین، تفاوت معنادار در توزیع مشتریان خوش‌حساب و بدحساب بین کشورها (نسبت ۱،۳۶:۱ در ایران، ۲،۳۳:۱ در آلمان، و ۰،۸۰:۱ در استرالیا) نشان داد که مدل‌های عمومی یکسان نمی‌توانند به‌طور مؤثر در همه بازارها استفاده شوند و نیاز به بومی‌سازی پارامترها بر اساس ویژگیهای اقتصادی - مالی هر منطقه ضروری است. از جنبه کاربردی، این چارچوب با کاهش خطاهای نوع اول (شناسایی نادرست مشتریان خوب به عنوان بدحساب) و نوع دوم (شناسایی نادرست مشتریان بد به عنوان خوشحساب)، ابزاری ارزشمند برای کاهش مطالبات غیرجاری بانک‌ها و افزایش شفافیت فرآیند اعطای وام فراهم می‌کند.

با توجه به یافته‌های این پژوهش، پیشنهاد می‌شود مطالعات آینده بر گسترش مدل به سمت ادغام داده‌های کیفی و رفتاری (مانند سابقه تعاملات مشتریان با بانک یا نوسانات بازار سرمایه) متمرکز شوند تا توانایی پیشبینی ریسک در شرایط پیچیده‌تر افزایش یابد. همچنین، توسعه نسخه‌های پویای مدل با قابلیت به‌روزرسانی خودکار پارامترها در مواجهه با تغییرات اقتصادی (مانند تورم یا تحریم‌ها) می‌تواند قابلیت اطمینان پیش‌بینی‌ها را در بلندمدت تقویت کند. در سطح الگوریتمی، آزمودن رویکردهای تفسیرپذیر (XAI) برای تحلیل نقش هر ویژگی در تصمیم‌گیری مدل، نه تنها شفافیت را افزایش می‌دهد، بلکه امکان تنظیم سیاستهای اعتباری مبتنی بر شواهد را فراهم می‌کند. علاوه بر این، نهادهای مالی و بانکی می‌توانند با بهره‌گیری از سیستم‌های رتبه‌بندی اعتباری پیشرفته که از تکنیک‌های یادگیری عمیق و جمعی بهره می‌برند، در کاهش ریسک اعتباری و جلوگیری از خسارات مالی گام‌های موثری بردارند. همچنین، ارائه شفافیت در نتایج مدل‌ها و توضیحات مربوط به انتخاب ویژگی‌ها، می‌تواند اعتماد نهادهای نظارتی را افزایش دهد. از این رو، توصیه می‌شود بانک‌ها با سرمایه‌گذاری در فناوری‌های هوش مصنوعی و بهبود سیستم‌های مدیریتی، از مدل‌های پیشرفته بهره‌مند شوند.

¹ Aruleba & Sun

² Rofik

منابع

- ابتیاع، مجید و همکاران. (۱۴۰۰). رتبه بندی اعتباری مشتریان بانک به کمک روش جدید گروهی بر پایه ماشین بردار پشتیبان: مطالعه موردی بانک پاسارگاد، محاسبات نرم، دوره ۱۰ (۲)، ۱۵-۲.
- اخباری، مهدیه؛ مخاطب رفیعی، فریماه. (۱۳۸۹). کاربرد سیستم های استدلال عصبی - فازی در رتبه بندی اعتباری مشتریان حقوقی بانک ها، **تحقیقات اقتصادی**، شماره ۹۲، صص. ۱-۲۱.
- اسراری، مصطفی. (۱۳۹۲). مقایسه کارایی مدل های شبکه عصبی، الگوریتم ژنتیک و لاجیت در ارزیابی ریسک اعتباری مشتریان حقیقی: مطالعه موردی در بانک کشاورزی، **پایان نامه کارشناسی ارشد، رشته MBA، گرایش مالی، دانشگاه علوم اقتصادی**.
- پاکباین، پرستو؛ پویانفر، احمد. (۱۳۹۷). رتبه بندی اعتباری مشتریان بانک با تکنیک طبقه بندی ترکیبی پویا و احتمال نرم (مطالعه موردی: بانک پاسارگاد)، **پایان نامه کارشناسی ارشد، رشته مهندسی مالی و مدیریت ریسک، دانشگاه خاتم**.
- جیحونی پور، مهرداد؛ اعظمی، سمیه؛ دل انگیزان، سهراب. (۱۴۰۳). مدل سازی و شناسایی روابط علی بین عوامل اصلی ریسک اعتباری در سیستم بانکی با استفاده از تکنیک تصمیم گیری دیمتل، **نشریه: سیاست گذاری اقتصادی**، ۱۷ (۳۳)، ۱۸۰-۲۱۱.
- حسامی، علی. (۱۳۹۸). امتیازدهی اعتباری مشتریان حقیقی بانکی با استفاده از روش یادگیری عمیق مورد مطالعه: مشتریان اعتباری یکی از بانک های ایرانی، **پایان نامه کارشناسی ارشد، مهندسی صنایع - سیستم های مالی، دانشگاه اراک**.
- خانجانی، محسن و همکاران. (۱۴۰۲). رتبه بندی اعتباری مشتریان حقوقی با استفاده از روش های یادگیری ماشین و یادگیری عمیق، **اولین کنفرانس بین المللی توانمندی مدیریت، مهندسی صنایع، حسابداری و اقتصاد**.
- دادمحمدی، دانیال؛ احمدی، عباس. (۱۳۹۳). رتبه بندی اعتباری مشتریان بانک با استفاده از شبکه عصبی با اتصالات جانبی، **فصلنامه توسعه مدیریت پولی و بانکی**، سال دوم، شماره ۳، تابستان ۱۳۹۳.
- کوچه باغی، سمیرا؛ رجبی بهجت، امیر. (۱۳۹۶). انتخاب زیرمجموعه ای از ویژگی ها مبتنی بر الگوریتم جستجوی گرانشی باینری برای رتبه بندی اعتباری مشتریان بانکی با استفاده از ترکیب الگوریتم های طبقه بندی، **پایان نامه کارشناسی ارشد، دانشگاه آزاد اسلامی، واحد بندرعباس**.
- گل محمدی، نسرين. (۱۳۹۵). رتبه بندی اعتباری مشتریان بانک با استفاده از الگوریتم فراابتکاری (ژنتیک) (مورد مطالعه: مشتریان حقیقی بانک مسکن - شعب منطقه غرب تهران)، **پایان نامه کارشناسی ارشد، مرکز آموزش عالی رجاء، دانشکده مهندسی صنایع**.
- مهدوی، کاوه؛ حری، محمدصادق. (۱۳۹۴). طراحی مدلی جهت پیش بینی رتبه اعتباری مشتریان بانکها با استفاده از الگوریتم فراابتکاری و هیبریدی چند معیاره شبکه عصبی فازی - کلونی مورچگان (مطالعه موردی شعب پست بانک استان تهران)، **پژوهش های مدیریت در ایران**، دوره ۱۹، شماره ۱، ۹۱-۱۱۶.
- ندیری، کامران؛ محرابی، لیلیا. (۱۳۹۷). بررسی انواع ریسک و مدیریت ریسک در نظام بانکداری اسلامی، **توسعه راهبرد**، ۵۴ (۱۴)، ۱۸۱-۱۶۰.
- نظرآقایی، مهدی. (۱۳۹۸). دسته بندی ریسک اعتباری مشتریان حقیقی با استفاده از یادگیری جمعی (مطالعه موردی بانک سپه)، **پژوهش های پولی - بانکی**، شماره ۳۹، ۱۲۹-۱۶۶.
- Abdou, H. A., Mitra, S., Fry, J., & Elamer, A. A. (2019). Would two-stage scoring models alleviate bank exposure to bad debt?. *Expert Systems with Applications*, 128, 1-13.
- Abellán, J., & Mantas, C. J. (2014). Improving experimental studies about ensembles of classifiers for bankruptcy
- Addy, W. A., Ugochukwu, C. E., Oyewole, A. T., & Chrisanctus, O. (2024). Predictive analytics in credit risk management for banks: A comprehensive review.
- Ala'raj, M., Abbod, M. F., Majdalawieh, M., & Jum'a, L. (2022). A deep learning model for behavioural credit scoring in banks. *Neural Computing and Applications*, 1-28.

- Almufti, S. M., Shaban, A. A., Ali, Z. A., Ali, R. I., & Fuente, J. A. D. (2023). Overview of Metaheuristic Algorithms. *Polaris Global Journal of Scholarly Research and Trends*, 2(2), 10-32.
- Aruleba, I., & Sun, Y. (2024). Effective credit risk prediction using ensemble classifiers with model explanation. *IEEE Access*.
- Attigeri, G. V., Pai, M. M., & Pai, R. M. (2017). Credit risk assessment using machine learning algorithms. *Advanced Science Letters*, 23(4), 3649-3653.
- Bhattacharya, A., Biswas, S. K., & Mandal, A. (2023). Credit risk evaluation: a comprehensive study. *Multimedia Tools and Applications*, 82(12), 18217-18267.
- Bielecki, T. R., & Rutkowski, M. (2013). *Credit risk: modeling, valuation and hedging*. Springer Science & Business Media.
- Cahn, C., Girotti, M., & Salvade, F. (2024). Credit ratings and the hold-up problem in the loan market. *Management Science*, 70(3), 1810-1831.
- Das, S. R. (2019). Credit risk derivatives. In *World Scientific Reference on Contingent Claims Analysis in Corporate Finance: Volume 3: Empirical Testing and Applications of CCA* (pp. 373-400).
- Du, P., & Shu, H. (2022). Exploration of financial market credit scoring and risk management and prediction using deep learning and bionic algorithm. *Journal of Global Information Management (JGIM)*, 30(9), 1-29.
- Dumitrescu, E., Hue, S., Hurlin, C., & Tokpavi, S. (2018). *Machine Learning for Credit Scoring: Improving Logistic Regression with Non Linear Decision Tree Effects (Doctoral dissertation, PhD thesis. Paris Nanterre University, University of Orleans)*.
- Eletter, S. F., & Yaseen, S. G. (2017). Loan decision models for the Jordanian commercial banks. *Global Business and Economics Review*, 19(3), 323-338.
- Gunnarsson, B. R., Vanden Broucke, S., Baesens, B., Óskarsdóttir, M., & Lemahieu, W. (2021). Deep learning for credit scoring: Do or don't?. *European Journal of Operational Research*, 295(1), 292-305.
- Joshi, S. (2025). Review of Gen AI Models for Financial Risk Management. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 11(1), 709-723.
- Khalili, N., & Rastegar, M. A. (2023). Optimal cost-sensitive credit scoring using a new hybrid performance metric. *Expert Systems with Applications*, 213, 119232.
- Lando, D. (2009). Credit risk modeling. In *Credit Risk Modeling*. Princeton University Press.
- Maleki, M. S., Motevallian, S. N., Hosseini, F., Sabokrou, M., & Maleki, H. S. (2021, October). Improvement of credit scoring by lstm autoencoder model. In *2021 11th International Conference on Computer Engineering and Knowledge (ICCKE)* (pp. 182-187). IEEE.
- Mpoftu, T. P., & Mukosera, M. (2014). Credit scoring techniques: a survey. *International Journal of Science and Research (IJSR)*, 2319-7064.
- Naili, M., & Lahrichi, Y. (2022). Banks' credit risk, systematic determinants and specific factors: recent evidence from emerging markets. *Heliyon*, 8(2).
- Rofik, R., Aulia, R., Musaadah, K., Ardyani, S. S. F., & Hakim, A. A. (2024). The optimization of credit scoring model using stacking ensemble learning and oversampling techniques. *Journal of Information System Exploration and Research*, 2(1).
- Suksamai, C., Hengpraprom, K., & Silachan, K. (2022, July). A Comparison of Normalization Data Transformation Efficiency Affecting with Bank Customer Credit Data Classification using Data Mining Techniques. *The 14th NPRU National Academic Conference Nakhon Pathom Rajabhat University*.
- Sutrisno, H., & Halim, S. (2017, September). Credit Scoring Refinement Using Optimized Logistic Regression. In *2017 International Conference on Soft Computing, Intelligent System and Information Technology (ICSIIIT)* (pp. 26-31). IEEE.
- Thomas, L., Crook, J., & Edelman, D. (2017). *Credit scoring and its applications*. Society for industrial and Applied Mathematics.
- Tripathi, D., Edla, D. R., & Cheruku, R. (2018). Hybrid credit scoring model using neighborhood rough set and multi-layer ensemble classification. *Journal of Intelligent & Fuzzy Systems*, 34(3), 1543-1549.
- Wang, Y., Jia, Y., Fan, S., & Xiao, J. (2023). Deep Reinforcement Learning Based on Balanced Stratified Prioritized Experience Replay for Customer Credit Scoring in Peer-to-Peer Lending.
- Zhang, R., Ligu, X., & Qin, W. An Ensemble Credit Scoring Model Based on Logistic Regression with Heterogeneous Balancing and Weighting Effects. *Available at SSRN 4167821*.
- Zhuang, Y., Xu, Z., & Tang, Y. (2015, September). A credit scoring model based on bayesian network and mutual information. In *2015 12th Web Information System and Application Conference (WISA)* (pp. 281-286). IEEE.