



Operational Risk Prediction in the Banking Industry Using Machine Learning Algorithms

Hamed Naderi

Ph.D. Candidate, Department of Industrial Engineering, Faculty of Industrial and Systems Engineering, Tarbiat Modares University, Tehran, Iran. E-mail: h.naderi@modares.ac.ir

Mohammad Ali Rastegar *

*Corresponding Author, Assistant Prof., Department of Systems and Productivity Management, Faculty of Industrial Engineering & Systems, Tarbiat Modares University, Tehran, Iran. E-mail: ma_rastegar@modares.ac.ir

Bakhtiar Ostadi

Associate Prof., Department of System and Productivity Management, Faculty of Industrial and Systems Engineering, Tarbiat Modares University, Tehran, Iran. E-mail: bostadi@modares.ac.ir

Mehrdad Kargari

Associate Prof., Department of Information Technology Engineering, Faculty of Industrial and Systems Engineering, Tarbiat Modares University, Tehran, Iran. E-mail: m_kargari@modares.ac.ir

Abstract

Objective

This research examines and enhances operational risk management in banks using machine learning algorithms. Effective management of operational risk, which arises from internal or external failures in processes, systems, and personnel, is crucial due to its significant impact on the performance and stability of banks. Its primary goal is to introduce an innovative approach to improving operational risk management in banks through machine learning algorithms. Given the importance of accurately predicting operational risks to prevent

Citation: Naderi, Hamed; Rastegar, Mohammad Ali; Ostadi, Bakhtiar & Kargari, Mehrdad (2025). Operational Risk Prediction in the Banking Industry Using Machine Learning Algorithms. *Financial Research Journal*, 27(4), 905-930. <https://doi.org/10.22059/FRJ.2025.383851.1007655> (in Persian)



potential losses and improve decision-making processes in the banking industry, this research purposes to enhance the accuracy and efficiency of risk prediction models. The focus is on leveraging real-world banking data and evaluating machine learning algorithms to identify the most effective methods for predicting different levels of operational risk.

Methods

This research employs machine learning algorithms to predict the occurrence levels of operational risks. The dataset consists of operational risk data from an Iranian bank collected from 2016 to 2023, comprising 4,213 records and 12 features. After preprocessing the data, various machine learning algorithms, including Decision Tree, Random Forest, Support Vector Machine, Logistic Regression, Naïve Bayes, and k-Nearest Neighbors, were utilized for training the models. The data was split into training and test sets in an 80/20 ratio and evaluated using K-fold cross-validation. Model performance was assessed based on metrics such as accuracy, precision, recall, F1-score, and the ROC-AUC curve, with the best model selected for future predictions.

Results

The findings show that the use of machine learning algorithms can significantly improve the accuracy of predicting operational risks in banks. In the evaluation of different algorithms, SVM and RF showed the best performance, particularly in classifying the third class (Label 3), where the model's accuracy with the AUC metric was close to one. These results highlight the high capability of these two algorithms in accurately distinguishing between different levels of operational risk. On the other hand, LR and NB demonstrated the weakest performance and failed to predict risks effectively. Overall, the findings indicate that more powerful algorithms like SVM and RF can enhance operational risk management in banks and prevent damage resulting from poor risk management.

Conclusion

The results demonstrate that machine learning algorithms can substantially enhance operational risk management in banks. In particular, advanced algorithms such as SVM and RF achieved higher accuracy in predicting operational risks and effectively identified complex and atypical patterns. These technologies, by improving efficiency and reducing the costs associated with risk management, help banks develop better strategies for mitigating operational risks. Therefore, the continuous application of these technologies can enhance banks' performance in operational risk management.

Keywords: Machine learning, Operational risk, Risk management, Risk prediction.

پیش‌بینی ریسک عملیاتی در صنعت بانکداری با استفاده از الگوریتم‌های یادگیری ماشین

حامد نادری

دانشجوی دکتری، گروه مهندسی صنایع، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران. رایانامه: h.naderi@modares.ac.ir

محمدعلی رستگار*

* نویسنده مسئول، استادیار، گروه مدیریت سیستم و بهره‌وری، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران. رایانامه: ma_rastegar@modares.ac.ir

بختیار استادی

دانشیار، گروه مدیریت سیستم و بهره‌وری، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران. رایانامه: bostadi@modares.ac.ir

مهرداد کارگری

دانشیار، گروه مهندسی فناوری اطلاعات، دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران. رایانامه: m_kargari@modares.ac.ir

چکیده

هدف: در این پژوهش، به بررسی و بهبود مدیریت ریسک عملیاتی در بانک‌ها با استفاده از الگوریتم‌های یادگیری ماشین پرداخته شده است. مدیریت مؤثر ریسک عملیاتی که از نقص‌های داخلی یا خارجی در فرایندها، سیستم‌ها و افراد نشئت می‌گیرد، به دلیل تأثیرهای منفی آن بر عملکرد و پایداری بانک‌ها، اهمیت بسیار زیادی دارد. هدف این پژوهش، ارائه رویکردی نوین برای بهبود مدیریت ریسک‌های عملیاتی در بانک‌ها با استفاده از تکنیک‌های یادگیری ماشین است. با توجه به اهمیت پیش‌بینی دقیق ریسک‌های عملیاتی، برای جلوگیری از خسارت‌های احتمالی و بهبود فرایندهای تصمیم‌گیری در صنعت بانکداری، این پژوهش به دنبال ارتقای دقت و کارایی مدل‌های پیش‌بینی ریسک است. تمرکز اصلی بر استفاده از داده‌های واقعی بانک‌ها و ارزیابی الگوریتم‌های یادگیری ماشین، به منظور شناسایی بهترین روش‌ها برای پیش‌بینی سطوح ریسک‌های مختلف است.

روش: در این پژوهش از الگوریتم‌های یادگیری ماشین برای پیش‌بینی سطح وقوع ریسک‌های عملیاتی استفاده شده است. داده‌ها از مجموعه داده‌های ریسک عملیاتی یکی از بانک‌های ایرانی در دوره زمانی ۱۳۹۵ تا ۱۴۰۲ با ۴۲۱۳ رکورد و ۱۲ ویژگی جمع‌آوری شدند. پس از پیش‌پردازش داده‌ها، از الگوریتم‌های مختلف یادگیری ماشین شامل درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان، رگرسیون لجستیک، بیز ساده و k نزدیک‌ترین همسایه، برای آموزش مدل‌ها استفاده شد. داده‌ها به نسبت ۸۰ به ۲۰ به مجموعه‌های

استناد: نادری، حامد؛ رستگار، محمدعلی؛ استادی، بختیار و کارگری، مهرداد (۱۴۰۴). پیش‌بینی ریسک عملیاتی در صنعت بانکداری با استفاده از الگوریتم‌های یادگیری ماشین. *تحقیقات مالی*، ۲۷(۴)، ۹۰۵-۹۳۰.

آموزشی و آزمون تقسیم و با استفاده از اعتبارسنجی متقابل K تایی ارزیابی شدند. عملکرد مدل‌ها با استفاده از معیارهایی نظیر دقت، صحت، یادآوری، F1-score و منحنی ROC-AUC سنجیده و بهترین مدل برای پیش‌بینی‌های آتی انتخاب شد.

یافته‌ها: یافته‌های این پژوهش نشان می‌دهد که استفاده از الگوریتم‌های یادگیری ماشین، می‌تواند به‌طور چشمگیری دقت پیش‌بینی ریسک‌های عملیاتی در بانک‌ها را افزایش دهد. در ارزیابی الگوریتم‌های مختلف، الگوریتم SVM و RF بهترین عملکرد را نشان دادند، به‌ویژه در طبقه‌بندی کلاس سوم که دقت مدل با معیار AUC نزدیک به ۱ بود. این نتایج از توانایی بالای این دو الگوریتم در تمایز دقیق بین سطوح مختلف ریسک‌های عملیاتی حکایت می‌کند. در مقابل، الگوریتم‌های LR و NB ضعیف‌ترین عملکرد را از خود نشان دادند و نتوانستند به‌خوبی ریسک‌ها را پیش‌بینی کنند. به‌طور کلی، یافته‌ها نشان می‌دهد که الگوریتم‌های قدرتمندی مانند SVM و RF می‌توانند ضمن کمک به بهبود مدیریت ریسک‌های عملیاتی در بانک‌ها، از آسیب‌های ناشت گرفته از مدیریت نادرست این ریسک‌ها جلوگیری کنند.

نتیجه‌گیری: این پژوهش نشان داد که استفاده از الگوریتم‌های یادگیری ماشین می‌تواند به‌طور درخور توجهی به بهبود مدیریت ریسک‌های عملیاتی در بانک‌ها کمک کند. الگوریتم‌های پیشرفته یادگیری ماشین، به‌ویژه SVM و RF، برای پیش‌بینی ریسک‌های عملیاتی دقت بیشتری ارائه دادند و امکان شناسایی الگوهای پیچیده و غیرمعمول را فراهم کردند. این فناوری‌ها با بهبود کارایی و کاهش هزینه‌های مربوط به مدیریت ریسک، به بانک‌ها کمک می‌کنند تا استراتژی‌های بهتری برای مقابله با ریسک‌های عملیاتی تدوین کنند؛ از این رو به‌کارگیری مستمر این فناوری‌ها می‌تواند عملکرد بانک‌ها را در زمینه مدیریت ریسک عملیاتی ارتقا بخشد.

کلیدواژه‌ها: ریسک عملیاتی، یادگیری ماشین، مدیریت ریسک، پیش‌بینی ریسک.

مقدمه

ریسک‌های بانکی، عامل بسیاری از بحران‌های مالی است و بر عملکرد اقتصاد در سطح کلان، آثار نامطلوبی می‌گذارد (تهرانی، سراج، فروش باستانی و فلاح‌پور، ۱۳۹۹). حداقل‌سازی ریسک، به همراه حداکثرسازی سود هدفی است که همواره بانک‌ها به دنبال تحقق آن هستند (باجلان، فلاح‌پور و رئیسی، ۱۴۰۳). بخش بانکی دارای بیشترین درجه تأثیرگذاری بر سایر بخش‌هاست که این موضوع بر بالا بودن ریسک در بخش بانکی دلالت دارد. به بیان دیگر، بخش بانکی به عنوان جزئی از نظام مالی کشور نسبت به سایر بخش‌ها اهمیت بیشتری دارد و در صورت وقوع بحران مالی در این بخش، به علت تأثیرگذاری کمابیش زیاد آن، به راحتی می‌تواند به سایر بخش‌ها سرایت کند (رحیمی باغی، عرب صالحی و واعظ برزانی، ۱۳۹۸).

در دههٔ پس از بحران مالی جهانی، بانک‌ها به طور فزاینده‌ای به ریسک‌های عملیاتی توجه بیشتری کرده‌اند. با این حال، هنوز بانک‌ها با چالش‌هایی در مدیریت مؤثر این نوع ریسک مواجهند (گونزالس کاراسکو، خیمنز مارکز، لوپز کوادرادو و رویزمز کوآ^۱، ۲۰۱۹؛ هافمن^۲، ۲۰۰۲). بر اساس توافق نامه بازل ۲، ریسک عملیاتی به احتمال وقوع زیان ناشی از رویدادهای داخلی مانند نقص‌ها، کاستی‌ها و نارسایی‌ها در فرایندها، سیستم‌ها یا افراد، یا به علت رویدادهای خارجی اشاره دارد (کمیتة بازل در مورد نظارت بانکی^۳، ۲۰۰۴). مؤسسه‌های مالی باید این ریسک را به طور مؤثر مدیریت کنند تا از پیامدهای منفی آن جلوگیری کنند یا آن را کاهش دهند. فرایند مدیریت شامل اندازه‌گیری ریسک عملیاتی است که باید به درک مناسبی از ابعاد این ریسک منجر شود. کمیتة بازل در زمینهٔ نظارت بانکی روش‌های مختلفی برای اندازه‌گیری ریسک عملیاتی ارائه کرده است. مؤسسه‌های مالی، علاوه بر رعایت الزامات قانونی، باید ریسک عملیاتی را با توجه به سطح ریسک‌پذیری و تحمل ریسک خود مدیریت کنند.

زیان‌های شایان توجهی که مؤسسه‌های مالی و غیرمالی از ناحیه مشکلات فرایندی و عوامل غیراعتباری و غیربازاری تجربه کرده‌اند، باعث جلب توجه مدیران و تصمیم‌گیرندگان به حوزه ریسک عملیاتی شده است. مدیریت ریسک عملیاتی یکی از مسائل مهم در صنعت بانکداری است که بر عملکرد بانک‌ها و مؤسسه‌های مالی تأثیرهای چشمگیری دارد. پژوهش‌های انجام‌شده نشان می‌دهد که پژوهشگران به زوایای مختلف این ریسک پرداخته‌اند. برخی به تعریف ریسک، برخی به طبقه‌بندی رویدادهای مرتبط، برخی به اندازه‌گیری و ویژگی‌های مدیریت ریسک و گروهی دیگر به تحلیل‌های مقایسه‌ای تمرکز داشته‌اند (برکات و حسینی^۴، ۲۰۱۳). ریسک عملیاتی زمانی بروز می‌کند که یک سازمان قادر نباشد که عملیات خود را صحیح اجرا کند و ادامهٔ این وضعیت به افت عملکرد سازمان و کاهش نرخ بازدهی سرمایه‌گذاری منجر شود (کمیتة بازل در مورد نظارت بانکی، ۲۰۰۶). به طور کلی، ریسک عملیاتی به دلیل احتمال بروز خطا و نقص در عملیات خاص یک بنگاه تجاری یا مالی به وجود می‌آید (وانگ و هسو^۵، ۲۰۱۳).

1. González-Carrasco, Jiménez-Márquez, López-Cuadrado & Ruiz-Mezcua

2. Hoffman

3. Basel Committee on Banking Supervision

4. Barakat & Hussainey

5. Wang & Hsu

در پژوهش قربانی، کردستانی، حقیقت، قائمی و عزیزمحمملو (۱۳۹۹) به ارائه مدل ارزیابی اثربخشی مدیریت ریسک در صنعت بانکی با در نظر گرفتن شرایط محیطی و استانداردهای بین‌المللی مانند بیانیه‌های کمیته بال و کوزو می‌پردازد. مدیریت ریسک‌های بانکی یکی از چالش‌های اساسی در صنعت بانکداری محسوب می‌شود که بر پایداری و عملکرد مالی بانک‌ها تأثیر مستقیمی دارد. در میان انواع ریسک‌های بانکی، ریسک عملیاتی، به دلیل ماهیت پیچیده و چندبُعدی خود، از اهمیت ویژه‌ای برخوردار است. این نوع ریسک، از نقص‌های داخلی یا خارجی در فرایندها، سیستم‌ها، افراد و عوامل خارجی نشأت می‌گیرد و در صورت مدیریت نادرست، می‌تواند به خسارت‌های مالی، آسیب به شهرت بانک و حتی ورشکستگی منجر شود. با توجه به افزایش پیچیدگی عملیات بانکی و حجم انبوه داده‌های تولیدشده، روش‌های سنتی مدیریت ریسک عملیاتی دیگر پاسخ‌گوی نیازهای بانک‌ها نیستند. در این راستا، بهره‌گیری از الگوریتم‌های یادگیری ماشین که قابلیت شناسایی الگوهای پنهان در داده‌ها و پیش‌بینی دقیق‌تر وقوع ریسک را دارند، می‌تواند برای بهبود مدیریت ریسک عملیاتی راه‌کار مؤثری باشد. این پژوهش به دنبال پاسخ به این پرسش کلیدی است که چگونه می‌توان با استفاده از الگوریتم‌های یادگیری ماشین، دقت و کارایی پیش‌بینی ریسک‌های عملیاتی در بانک‌ها را افزایش داد و به تصمیم‌گیری‌های بهینه در مدیریت ریسک کمک کرد.

هدف اصلی این پژوهش، ارائه مدلی مبتنی بر الگوریتم‌های یادگیری ماشین برای پیش‌بینی ریسک‌های عملیاتی در بانک‌هاست. با استفاده از این مدل، بانک‌ها می‌توانند با دقت بیشتری وقوع ریسک‌های عملیاتی را پیش‌بینی و استراتژی‌های مناسبی برای کاهش آن‌ها اتخاذ کنند. ضرورت انجام این پژوهش، در نیاز روزافزون بانک‌ها به ابزارهای پیشرفته برای مدیریت ریسک‌های عملیاتی نهفته است؛ زیرا مدیریت ناکارآمد ریسک‌ها می‌تواند تأثیرهای مخربی بر عملکرد مالی و عملیاتی بانک‌ها داشته باشد.

پیشینه پژوهش

ریسک عملیاتی به خطراتی اطلاق می‌شود که از عوامل خارجی یا نقص در کنترل‌های داخلی و سیستم‌های اطلاعاتی به وجود می‌آید و ممکن است به زیان‌هایی منجر شود که این زیان‌ها می‌توانند پیش‌بینی‌شده یا غیرمنتظره باشند (کروچی، گالای و مارک^۱، ۱۹۹۸). تریپ^۲ (۲۰۰۰) ریسک عملیاتی را به عنوان خطر از دست دادن عملیات توصیف می‌کند. توافق‌نامه بازل ۲، ریسک عملیاتی را به عنوان احتمال زیان ناشی از کمبودها، خرابی‌ها یا نارسایی‌ها در منابع انسانی، فرایندها، فناوری‌ها، زیرساخت‌ها یا رویدادهای داخلی و خارجی تعریف می‌کند (پنا، بونت، لوچمولر، چیکلانا و گونگورا^۳، ۲۰۱۸). ریسک‌های عملیاتی در نظام بانکداری اسلامی نیز، یکی از موضوعات مورد توجه در حوزه پژوهش‌های مالی است. در این راستا، مطالعات متعددی به بررسی و دسته‌بندی این ریسک‌ها پرداخته‌اند. برای نمونه، طالبی، کاوند و حسین‌پور (۱۳۹۰) در پژوهشی توصیفی - تحلیلی، ریسک‌های عملیاتی در بانکداری اسلامی را به دو

1. Crouchy, Galai & Mark

2. Tripe

3. Pena, Bonet, Lochmuller, Chiclana & Góngora

دسته کلی تقسیم کرده‌اند: نخست، ریسک‌هایی که با نظام بانکی متعارف مشترک هستند و دوم، ریسک‌های خاص بانکداری اسلامی. یافته‌های این مطالعه نشان می‌دهد که تفکیک این دو گروه ریسک می‌تواند در مدیریت مؤثرتر آن‌ها نقش بسزایی داشته باشد.

بر اساس توافق‌نامه بازل، برای محاسبه سرمایه مورد نیاز جهت پوشش ریسک‌های عملیاتی، سه رویکرد وجود دارد: شاخص پایه، استاندارد و اندازه‌گیری پیشرفته (مورا والنسیا و زاپاتا جارامیلو^۱، ۲۰۱۷؛ مورا والنسیا، ۲۰۱۰). رویکردهای شاخص پایه و استاندارد به تخمین سرمایه پوششی بر اساس درآمد ناخالص سالیانه می‌پردازند. در رویکرد استاندارد، فعالیت‌های بانک به ۸ خط کسب‌وکار تقسیم می‌شود و هر خط کسب‌وکار دارای ضریب بتا (β) مخصوص به خود است که بین ۱۲ تا ۱۸ درصد قرار دارد. در حالی که در رویکرد شاخص پایه، از ضریب آلفا (α) ۱۵ درصد استفاده می‌شود. رویکرد اندازه‌گیری پیشرفته، شامل استفاده از روش‌های کمی و کیفی برای مدل‌سازی ریسک عملیاتی است و به استفاده از پایگاه‌های داده برای جمع‌آوری داده‌های آماری مورد نیاز و استفاده از توزیع زیان برای برازش توزیع‌های فراوانی و شدت می‌پردازد. سرمایه پوششی در این روش، بر اساس توزیع تجمعی فراوانی و شدت محاسبه می‌شود. به دلیل نیاز به داده‌های دقیق، این روش به پایگاه داده‌های مختلفی همچون پایگاه داده داخلی، پایگاه داده خارجی، پایگاه داده تجزیه و تحلیل مبتنی بر سناریو و پایگاه داده عوامل محیط کسب‌وکار و کنترل داخلی نیازمند است (کمیت بازل در مورد نظارت بانکی، ۲۰۰۴). در حوزه سنجش و برآورد سرمایه مورد نیاز برای ریسک عملیاتی، نصرتی و پاکیزه (۱۳۹۳) با بهره‌گیری از رویکردهای پیشرفته، از مدل‌های مبتنی بر توزیع زیان برای محاسبه ذخایر سرمایه در بانک‌ها استفاده کردند. در این پژوهش، علاوه بر مدل‌های کلاسیک، از توزیع‌های دنباله پهن مانند توزیع آلفا پایدار نیز بهره گرفته شد تا چارچوبی کاربردی برای مدیریت سرمایه در برابر ریسک‌های عملیاتی ارائه شود. علاوه بر این، مصطفائی دولت آباد، آذر و مقبل باعرض (۱۳۹۷) از تکنیک نگاشت شناختی فازی برای شناسایی و تحلیل ساختاریافته ریسک‌های عملیاتی استفاده کردند. این پژوهش با ارائه یک چارچوب فرایندی، به بانک‌ها کمک می‌کند تا بتوانند شناسایی، ارزیابی و مدیریت بهتری بر این ریسک‌ها داشته باشند. در این مطالعه، تأکید ویژه‌ای بر قابلیت‌های نگاشت شناختی در درک روابط پیچیده میان عوامل مؤثر بر ریسک‌های عملیاتی شده است.

در پژوهشی دیگر، خوش‌سیما و شهیکی‌تاش (۱۳۹۱) به بررسی رابطه بین کارایی بانک‌ها و انواع ریسک‌های اعتباری، عملیاتی و نقدینگی پرداخته‌اند. آن‌ها از روش‌های پارامتریک و ناپارامتریک برای تحلیل داده‌ها استفاده کردند و نتایج نشان داد که این ریسک‌ها تأثیر معناداری بر کارایی بانک‌های ایران دارند. این یافته‌ها بر اهمیت تجزیه و تحلیل دقیق‌تر و اتخاذ راه‌کارهای مدیریتی جامع‌تر تأکید دارند. درک جامع و دقیق از ابعاد مختلف ریسک‌های عملیاتی، یکی از پیش‌نیازهای اساسی برای مدیریت اثربخش آن‌ها است. نادری و رستگار (۱۴۰۱) در پژوهشی که با استفاده از روش فراترکیب انجام شده است، چارچوبی جامع برای مدیریت ریسک عملیاتی در صنعت بانکداری ارائه کرده‌اند. در این مطالعه، با بررسی و تجزیه و تحلیل یافته‌های پژوهش‌های پیشین، ابعاد گوناگون این ریسک‌ها شناسایی و طبقه‌بندی شده

است. چارچوب پیشنهادی آن‌ها می‌تواند به مدیران بانکی کمک کند تا با نگاهی ساختاریافته‌تر، راه کارهای بهتری برای کاهش اثرهای منفی این نوع ریسک‌ها طراحی و اجرا کنند. روش‌های استنتاج بیزی نیز در برخی پژوهش‌ها برای تحلیل ریسک‌های عملیاتی مورد استفاده قرار گرفته است. برای مثال، استادی، خزایی و حسین‌زاده کاشان (۱۳۹۷) با ترکیب داده‌های داخلی و نظرات کارشناسان، به ارزیابی این ریسک‌ها پرداختند. یافته‌های آن‌ها نشان داد که با افزایش دوره‌های پیش‌بینی، میزان زیان مورد انتظار کاهش می‌یابد که این امر می‌تواند به معنای کاهش تدریجی ریسک عملیاتی در طول زمان باشد.

مدیریت و اندازه‌گیری ریسک عملیاتی در مقایسه با سایر ریسک‌های بانکی مانند ریسک‌های اعتباری و بازار پیچیده‌تر و دشوارتر است. این ریسک، به‌ویژه برای نهادهای مالی، اهمیت بسیار زیادی دارد و در سال‌های اخیر توجه زیادی را جلب کرده است؛ زیرا زیان‌های بزرگ عملیاتی می‌توانند به انحلال مؤسسه‌های مالی منجر شوند (ابدیمومونوف، کورتی و میهوف^۱، ۲۰۲۰؛ افسونو، کورتی و میهوف^۲، ۲۰۱۹). کریسانتو و پرنیو^۳ (۲۰۱۷) شناسایی کرده‌اند که تهدیدهای سایبری و کلاهبرداری سایبری می‌توانند تأثیر چشمگیری بر فرایند تخمین سرمایه ریسک عملیاتی داشته باشند. این جرایم که با گسترش خدمات بانکداری الکترونیکی افزایش یافته‌اند، شامل دسترسی غیرقانونی، اختلال در سیستم و سوءاستفاده یا دزدی از دستگاه‌ها به‌منظور کسب مزیت مالی است (کمیته بازل در مورد نظارت بانکی، ۲۰۱۶؛ درو و فارل^۴، ۲۰۱۸). خرستینا، دوروفیف، کاجورینا، اوسوبالیف و دوبروتورسکی^۵، ۲۰۱۷ با استفاده از الگوریتم‌های یادگیری ماشین از جمله رگرسیون لجستیک، به دنبال توسعه الگوریتم‌های جست‌وجو، تجزیه و تحلیل و کشف فعالیت‌های متقلبانه در حوزه مالی، برای تشخیص تراکنش‌های متقلبانه بودند. پان و لاوریشین^۶ (۲۰۱۲) با استفاده از الگوریتم‌های بیز ساده، k نزدیک‌ترین همسایه و درخت تصمیم مدلی برای بهبود تشخیص تقلب کارت اعتباری ارائه دادند. صادقی مقدم، مهرگان و بهرام بیگ (۱۴۰۳) با استفاده از الگوریتم‌های یادگیری ماشین، به دنبال کاهش هزینه تشخیص تقلب در تراکنش‌های کارت‌های اعتباری بودند. همچنین شارما و چودوری^۷ (۲۰۱۶) توانستند با استفاده از الگوریتم‌های یادگیری بدون نظارت، مدلی برای شناسایی اقدامات متقلبانه در زمینه کارت‌های اعتباری و پول‌شویی انجام دهند.

برای برآورد زیان‌های احتمالی در معاملات بانکداری الکترونیکی، مدل شبکه بیزی (BN)^۸ برای تخمین سرمایه پوششی ریسک عملیاتی در شرکت‌های مالی توسعه یافته است (بوورت^۹، ۲۰۱۸). یادگیری ماشین به‌عنوان یکی از رویکردهای امیدوارکننده و چالش‌برانگیز در امور مالی مدرن مطرح شده است (تسای و وو^{۱۰}، ۲۰۰۸) و یادگیری عمیق

1. Abdymomunov, Curti & Mihov
2. Afonso
3. Crisanto & Prenio
4. Drew & Farrell
5. Khrestina, Dorofeev, Kachurina, Usabaliev & Dobrotvorskiy
6. Pun & Lawryshyn
7. Sharma & Choudhury
8. Bayesian network
9. Bouveret
10. Tsai & Wu

(DL)^۱ به دلیل قابلیت‌های تطبیق‌پذیری و پیش‌بینی، توجه زیادی را جلب کرده است. در پژوهش پنا و همکاران^۲ (۲۰۲۱)، از مدل یادگیری عمیق کانولوشنال فازی برای تخمین حداکثر ارزش در معرض خطر ریسک عملیاتی با سطح اطمینان ۹۹/۹ درصد استفاده شده است. همچنین، در پژوهش ژو، کی، شیائو و ونگ^۳ (۲۰۲۰)، با استفاده از الگوریتم‌های الگوریتم‌های یادگیری ماشین نیمه‌نظارت شده، تلاش شده است تا ریسک‌های عملیاتی بر اساس اخبار مالی طبقه‌بندی شوند. این پژوهش از ۵۸۴۳ سند مرتبط با اخبار مالی در منطقه آسیا و اقیانوسیه برای بازه زمانی فوریه ۲۰۱۹ تا مارس ۲۰۱۹ استفاده کرده است و مدل ارائه شده قادر به پیش‌بینی انواع ریسک‌های صنعت بانکداری است. در پژوهش دیگری توسط اکبری و یزدانیان (۱۴۰۲)، الگوریتم‌های یادگیری ماشین برای تخمین آستانه مناسب برای داده‌های شدت زیان عملیاتی و طبقه‌بندی این داده‌ها به کار رفته است و سرمایه مورد نیاز برای پوشش ریسک عملیاتی با تجمیع تابع توزیع شدت و فراوانی داده‌ها و شبیه‌سازی مونت کارلو به دست آمده است.

مدیریت ریسک عملیاتی یکی از چالش‌هایی صنعت بانکداری است با بررسی پژوهش‌های گذشته، این موضوع کاملاً مشهود است. پژوهشگران مختلفی در مطالعاتی در حوزه مدیریت ریسک عملیاتی انجام داده‌اند. این پژوهش‌ها اغلب به محاسبه مقدار سرمایه مورد نیاز برای پوشش ریسک عملیاتی، پیش‌بینی تقلب‌های داخل و خارج بانک و دسته‌بندی ریسک‌های عملیاتی مربوط است. در این پژوهش تلاش شده است که با بهره‌گرفتن از رویکردهای یادگیری ماشین مدیریت ریسک عملیاتی بهبود داده شود.

یکی از چالش‌هایی که در حوزه مدیریت ریسک عملیاتی وجود دارد، تشخیص سطح ریسک عملیاتی است. با تشخیص درست سطح ریسک عملیاتی، مدیر ریسک می‌تواند بهترین استراتژی را برای مقابله با ریسک به وجود آمده اتخاذ کند. با استفاده از رویکردهای یادگیری ماشین می‌توان سطوح مختلف ریسک عملیاتی پیش‌بینی شود و استراتژی‌های مقابله با ریسک برای مدیریت ریسک اتخاذ شود.

روش‌شناسی پژوهش

در این پژوهش از مجموعه داده ریسک عملیاتی بانک پارسیان استفاده شده است. این مجموعه داده به سال ۱۳۹۵ تا ۱۴۰۲ مربوط است که ۴۲۱۳ رکورد و ۱۲ ویژگی دارد. مجموعه داده مورد استفاده، طبق دستورالعمل کمیته بال جمع‌آوری شده است (کمیته بازل در مورد نظارت بانکی، ۲۰۰۴؛ پیرا و پیرا^۴، ۲۰۱۸). نمره ویژگی‌هایی مانند احتمال وقوع ریسک، ریسک، اثر وقوع ریسک و امتیاز ریسک براساس دستورالعمل کوزو^۵ ۲۰۱۷ داده شده است (کوزو، ۲۰۱۷). در جدول ۱ ویژگی مجموعه داده قابل مشاهده است.

1. Deep Learning

2. Pena et al.

3. Zhou, Qi, Xiao & Wang

4. Pereira & Pereira

5. Committee of Sponsoring Organizations of the Treadway Commission (COSO)

جدول ۱. ویژگی‌های مجموعه داده

ویژگی	نوع ویژگی	توضیحات
خط کسب‌وکار	کیفی	نوع خط کسب‌وکار بانک مورد مطالعه
عنوان اصلی	کیفی	عنوان اصلی ریسک در هر خط کسب‌وکار
عنوان فرعی	کیفی	عنوان فرعی ریسک در هر خط کسب‌وکار
فرایند اصلی	کیفی	فرایندهای اصلی که در بانک مورد مطالعه انجام می‌شود.
فرایند فرعی	کیفی	فرایندهای فرعی که در بانک مورد مطالعه انجام می‌شود.
عامل وقوع رویداد	کیفی	عواملی که باعث وقوع ریسک شده است.
نوع رویداد	کیفی	رویدادهای که رخ داده است.
مالک ریسک	کیفی	مالک ریسک رخ داده در واحد مربوطه.
محل وقوع ریسک	کیفی	محلی که ریسک در آن رخ داده است.
احتمال وقوع ریسک	کمی	نمره احتمال وقوع ریسک
اثر وقوع ریسک	کمی	نمره اثر وقوع ریسک
امتیاز ریسک	کمی	از حاصل ضرب احتمال در اثر وقوع ریسک

در ماتریس ریسک کوزو، احتمال وقوع ریسک و اثر وقوع ریسک در ۵ سطح نمره‌دهی شده است که در شکل ۱ مشاهده می‌شود. همچنین امتیاز ریسک نیز در سه سطح کم، متوسط و زیاد طبقه‌بندی شده که در مدل ارائه شده این سه سطح به‌عنوان سه کلاس مختلف در نظر گرفته شده است. در جدول ۲ کلاس سطوح ریسک مشخص شده است.

Likelihood	Almost certain 5	Low 5	Medium 10	High 15	High 20	High 25
	Likely 4	Low 4	Medium 8	Medium 12	High 16	High 20
	Possible 3	Low 3	Low 6	Medium 9	Medium 12	High 15
	Unlikely 2	Low 2	Low 4	Medium 6	Medium 8	Medium 10
	Rare 1	Low 1	Low 2	Low 3	Medium 4	Medium 5
		Insignificant 1	Minor 2	Serious 3	Disastrous 4	Catastrophic 5
		Impact				

شکل ۱. ماتریس ریسک

جدول ۲. سطوح ماتریس ریسک

سطح ریسک	کلاس
Low	۱
Medium	۲
High	۳

ویژگی‌هایی که در مدل یادگیری ماشین مورد استفاده قرار گرفته است، به این صورت است که خط کسب‌وکار، عنوان اصلی ریسک، عنوان فرعی ریسک، فرایند اصلی ریسک، فرایند فرعی ریسک، عامل وقوع رویداد، نوع رویداد، مالک ریسک و محل وقوع ریسک، به‌عنوان ورودی‌های مدل و سطح ریسک، به‌عنوان خروجی مدل در نظر گرفته شده است. خروجی این پژوهش سطح ریسک است که شامل سه کلاس ۱، ۲، ۳ (کم، متوسط و زیاد) است؛ بنابراین هر کلاس معرف یک سطح ریسک است. جدول ۳ توزیع کلاس‌ها به همراه تعداد و درصد هر کلاس را نشان می‌دهد. در جدول ۴ آمار توصیفی داده‌های این پژوهش قابل مشاهده است.

جدول ۳. توزیع کلاس‌های ریسک

کلاس	تعداد	درصد
۱	۲۰۳۴	۰/۴۸
۲	۱۴۲۳	۰/۳۴
۳	۷۵۶	۰/۱۸

جدول ۴. آمار توصیفی داده‌های پژوهش

ویژگی	میانگین	میانه	مد	کمترین	بیشترین	انحراف معیار	واریانس
خط کسب‌وکار	۱/۴۲۹۱۴۸	۱	۱	۱	۸	۱/۱۴۲۳۰۸	۱/۳۰۴۸۶۷
عنوان اصلی ریسک	۳/۰۸۸۰۶۱	۳	۵	۱	۵	۱/۸۱۳۲۳۷	۳/۲۸۷۸۲۸
عنوان فرعی ریسک	۲۹/۵۳۵۰۱۱	۲۴	۲۴	۱	۷۳	۱۵/۴۳۵۶۸۰	۲۳۸/۲۶۰۲۲۹
فرایند اصلی	۳/۲۶۴۴۲۰	۳	۱	۱	۷	۲/۰۳۱۲۹۸	۴/۱۲۶۱۷۲
فرایند فرعی	۱۶/۰۴۴۱۴۹	۱۳	۱	۱	۴۹	۱۳/۶۴۵۷۸۵	۱۸۶/۲۰۷۴۵۲
عامل وقوع رویداد	۳/۰۸۷۱۱۱	۳	۳	۱	۴	۰/۸۵۶۱۰۳	۰/۷۳۲۹۱۳
نوع رویداد	۳/۱۵۷۸۴۵	۲	۲	۱	۷	۱/۶۹۵۷۶۰	۲/۸۷۵۶۰۱
مالک ریسک	۱/۵۴۵۹۲۹	۱	۱	۱	۲۰	۲/۳۱۰۸۵۹	۵/۳۴۰۰۶۷
محل وقوع ریسک	۱۲۴/۰۷۳۱۰۷	۱۲۲	۱۲۳	۱	۳۰۲	۷۴/۰۸۷۷۰۲	۵۴۸۸/۹۸۷۵۳۲
سطح ریسک	۱/۵۲۲۴۳۱	۱	۱	۱	۳	۰/۸۴۰۴۴۴	۰/۷۰۶۳۴۶

در این پژوهش از ۶ الگوریتم پرکاربرد یادگیری ماشین استفاده شده است. در جدول ۵ این الگوریتم‌ها توضیح داده

شده است.

جدول ۵. الگوریتم‌های مورد استفاده

الگوریتم	توضیحات	منبع
k نزدیک‌ترین همسایه (KNN) ^۱	یک الگوریتم یادگیری ماشین است که به‌طور گسترده برای مسائل طبقه‌بندی و رگرسیون استفاده می‌شود. فرض نزدیکی نقاط مشابه اساس الگوریتم KNN است.	پونگودی، نگویان، حامدی و چنگیز ^۲ ، ۲۰۲۱
بیز ساده (NB) ^۳	یک الگوریتم طبقه‌بندی ساده، اما مؤثر و متداول یادگیری ماشین است که در دسته یادگیری با ناظر ^۴ جای می‌گیرد. بیز ساده الگوریتمی احتمالی است که براساس نظریه بیز برای طبقه‌بندی استفاده می‌شود.	لیو و همکاران ^۵ ، ۲۰۱۷
جنگل تصادفی (RF) ^۶	یک مدل طبقه‌بندی و رگرسیون مبتنی بر مجموعه است. از جنگل تصادفی می‌توان برای انتخاب ویژگی نیز استفاده کرد.	سیمایا، لیلهور، پراساد و ورما ^۷ ، ورما ^۸ ، ۲۰۲۱
رگرسیون لجستیک (LR) ^۹	این الگوریتم برای مسائل طبقه‌بندی بر اساس ویژگی‌های دو کلاسه ترجیح داده می‌شود. این یک تکنیک آماری است که داده‌های دریافتی حاصل از یافته‌های قبلی از مجموعه داده‌های داده شده را پیش‌بینی می‌کند.	سیمایا و همکاران ^۹ ، ۲۰۲۱
درخت تصمیم (DT) ^{۱۰}	درخت تصمیم یک الگوریتم یادگیری ماشین است که برای طبقه‌بندی داده‌ها استفاده می‌شود. طبقه‌بندی درخت تصمیم یکی از رایج‌ترین انواع مدل‌های طبقه‌بندی است.	جبار، دیکشاتولو و چاندرا ^{۱۱} ، ۲۰۱۶
ماشین بردار پشتیبان (SVM) ^{۱۲}	این الگوریتم مبتنی بر طبقه‌بندی نظارت شده است که می‌تواند برای یافتن راه‌حلی برای وظایف مختلف رگرسیون و طبقه‌بندی استفاده شود.	گارگ، لیلهور، قوش، پراساد و سیمایا ^{۱۳} ، ۲۰۲۱

بعد از طراحی مدل لازم است که صحت عملکرد مدل ارزیابی شود. پژوهش حاضر به دنبال پیش‌بینی سطح وقوع ریسک عملیاتی با استفاده از الگوریتم‌های یادگیری ماشین است؛ بنابراین یکی از سؤال‌هایی که مطرح می‌شود، این است که عملکرد کدام الگوریتم در پیش‌بینی سطح وقوع ریسک عملیاتی بهتر است. در این پژوهش از معیارهای ارزیابی ماتریس درهم‌ریختگی^{۱۴} استفاده شده است که در جدول ۶ مشاهده می‌شود. معیارهای ارزیابی شامل دقت^{۱۵}، صحت^{۱۶}،

1. K-Nearest Neighbor
2. Poongodi, Nguyen, Hamdi & Cengiz
3. Naive Bayes
4. Supervised Learning
5. Liu et al.
6. Random Forest
7. Simaiya, Lilhore, Prasad & Verma
8. Logistic Regression
9. Simaiya et al.
10. Decision Tree
11. Jabbar, Deekshatulu & Chandra
12. Support Vector Machine
13. Garg, Lilhore, Ghosh, Prasad & Simaiya
14. Confusion Matrix
15. Accuracy
16. Precision

بازخوانی^۱، F1-score و AUC است که دقت و صحت مهم‌ترین این معیارها محسوب می‌شوند. معیار دقت^۲ به تعداد نمونه‌های که از کل نمونه‌ها به درستی شناسایی شده است (گو، دینگ، یائو، لیانگ و یو^۳، ۲۰۲۰). صحت و یادآوری توانایی مدل را برای تشخیص درست یک نمونه کلاس مثبت شناسایی می‌کند (کانتارلا، فراکارولی و ولپه^۴، ۲۰۱۹؛ افروز، افروز، برنان و گرینستاد^۵، ۲۰۱۲). F1-Score میانگین هارمونیک یادآوری و صحت یک مدل پیش‌بینی را تعیین می‌کند (گوت و گاوسیر^۶، ۲۰۰۵). حساسیت^۷ تحت عنوان نرخ مثبت درست نامیده می‌شود. خصوصیت^۸ نیز نشان‌دهنده نمونه‌های نمونه‌های منفی است که درست پیش‌بینی شده است. جزئیات مربوط به معیارهای ارزیابی در جدول ۷ ذکر شده است.

جدول ۶. ماتریس درهم‌ریختگی

پیش‌بینی شده		ماتریس سردرگمی	
منفی	مثبت		
FP	TP	مثبت	واقعی
TN	FN	منفی	


- مثبت درست (TP): تعداد نمونه‌های مثبتی که به‌طور درست پیش‌بینی شده‌اند.
- منفی درست (TN): تعداد نمونه‌های منفی که توسط مدل درست پیش‌بینی شده‌اند.
- مثبت غلط (FP): تعداد نمونه‌های منفی که توسط مدل به اشتباه به‌عنوان مثبت پیش‌بینی شده‌اند.
- منفی غلط (FN): تعداد نمونه‌های مثبتی که توسط مدل به اشتباه به‌عنوان منفی پیش‌بینی شده‌اند.

جدول ۷. معیارهای ماتریس درهم‌ریختگی

اندازه‌گیری	فرمول
Accuracy	$(TP + TN) / (TP + FP + FN + TN)$
Precision	$TP / (TP + FP)$
Recall	$TP / (TP + FN)$
F1-score	$2 * Precision * Recall / (Precision + Recall)$
Sensitivity	$TP / (TP + FN)$
Specificity	$TN / (TN + FP)$

1. Recall
2. Accuracy
3. Guo, Ding, Yao, Liang & Yu
4. Cantarella, Fraccaroli & Volpe
5. Afroz, Brennan & Greenstadt
6. Goutte & Gaussier
7. Sensitivity
8. Specificity
9. True Positive
10. True Negative
11. False Positive
12. False Negative

شکل ۲ به‌طور جامع فرایند توسعه یک مدل پیش‌بینی در پژوهش را نمایش می‌دهد که از جمع‌آوری و پیش‌پردازش داده‌ها آغاز می‌شود. در ابتدا، داده‌ها برای آماده‌سازی جهت مدل‌سازی جمع‌آوری شده و پیش‌پردازش می‌شوند. سپس، برای ارزیابی دقیق مدل، از اعتبارسنجی متقابل K تایی استفاده می‌شود و داده‌ها به دو دسته آموزشی و آزمون (۸۰ درصد برای آموزش و ۲۰ درصد برای آزمون) تقسیم می‌شوند. مدل با استفاده از الگوریتم‌های مختلف یادگیری ماشین، از جمله درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان، رگرسیون لجستیک، بیز ساده و k نزدیک‌ترین همسایه آموزش داده می‌شود. پس از ایجاد مدل‌های پیش‌بینی، عملکرد آن‌ها با معیارهایی نظیر دقت، صحت پیش‌بینی، یادآوری، F1-score و منحنی ROC-AUC ارزیابی می‌شود. در نهایت، بهترین مدل انتخاب و به‌عنوان مدل نهایی برای پیش‌بینی‌های آتی استفاده می‌شود. این فرایند به شکلی سیستماتیک مراحل کلیدی را از ابتدا تا انتخاب بهترین مدل به تصویر می‌کشد و به خواننده دیدگاهی جامع از روش‌های به‌کار گرفته شده در پژوهش انجام شده را می‌دهد.

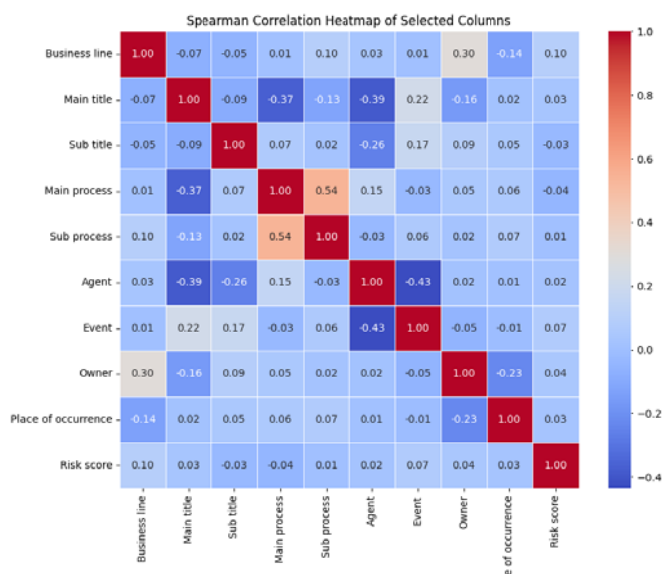


شکل ۲. مراحل اجرای مدل

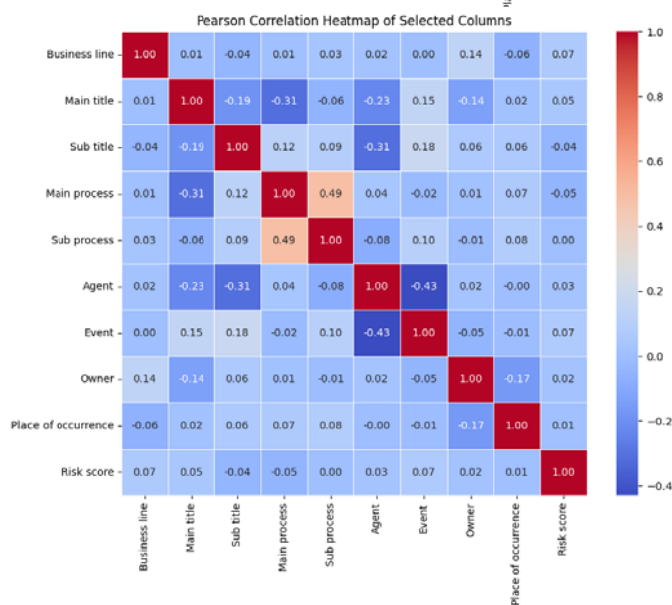
یافته‌های پژوهش

در رویکردهای یادگیری ماشین، لازم است ارتباط بین متغیرهای مسئله به دقت شناسایی شود. در این پژوهش، این ارتباط با استفاده از ماتریس هم‌بستگی مورد بررسی قرار گرفته است. در این ماتریس، متغیرها همان ویژگی‌های مجموعه داده هستند. ماتریس مذکور دارای ۱۰ سطر و ۱۰ ستون بوده و از ساختاری متقارن برخوردار است. تعداد سطرها و ستون‌ها با تعداد ویژگی‌های مجموعه داده برابر است. هر خانه از ماتریس با رنگی مشخص شده است که مقداری بین منفی ۱ تا مثبت ۱ را نشان می‌دهد. هرچه این مقدار به منفی ۱ نزدیک‌تر باشد، ارتباط معکوس بین دو ویژگی در نقطه تقاطع آن‌ها را نشان می‌دهد. به همین ترتیب، هرچه این مقدار به مثبت ۱ نزدیک‌تر باشد، نشانگر ارتباط مستقیم بین آن دو ویژگی است. قطر اصلی این ماتریس دارای مقدار ۱ است، زیرا هر ویژگی با خودش هم‌بستگی کامل دارد. برای اندازه‌گیری ضریب هم‌بستگی، روش‌های مختلفی وجود دارد. یکی از این روش‌ها که یک روش پارامتری

است، ضریب هم‌بستگی پیرسون^۱ نامیده می‌شود. روش دیگر که ناپارامتری است، ضریب هم‌بستگی اسپیرمن^۲ است. در شکل ۳، ماتریس هم‌بستگی پیرسون و در شکل ۴، ماتریس هم‌بستگی اسپیرمن نمایش داده شده است. با توجه به نتایج حاصل از ضریب هم‌بستگی با استفاده از این دو روش، مشخص شد که هیچ هم‌بستگی مثبت یا منفی معناداری بین متغیرها وجود ندارد.



شکل ۳. ماتریس هم‌بستگی پیرسون



شکل ۴. ماتریس هم‌بستگی اسپیرمن

نتایج این پژوهش عملکرد الگوریتم‌های مختلف یادگیری ماشین بر اساس معیارهای گوناگون ارزیابی برای سه کلاس (کلاس ۱، کلاس ۲ و کلاس ۳) را نشان می‌دهد. الگوریتم‌ها شامل SVM، RF، DT، LR، NB و KNN هستند. این نتایج در ذیل به‌طور دقیق بررسی شده است.

1. Pearson Correlation Coefficient
2. Spearman Correlation Coefficient

۱. ماشین بردار پشتیبان

ماشین بردار پشتیبان بهترین عملکرد را در میان الگوریتم‌های بررسی‌شده دارد. دقت کلی مدل برابر با ۰/۹۴۴۴ است که بسیار بالا و نشان‌دهنده قدرت مدل در پیش‌بینی صحیح است. همچنین، دقت متقابل^۱ نیز نسبتاً بالا و برابر با ۰/۹۱۰۳ است. این نتیجه نشان می‌دهد که مدل ماشین بردار پشتیبان به‌طور کلی توانسته است با داده‌های مختلف به‌خوبی کار کند و تعمیم‌پذیری بالایی دارد.

- کلاس ۱: با AUC برابر با ۰/۹۷۷۴ و F1-score برابر با ۰/۹۱۹۵، عملکرد بسیار خوبی را نشان می‌دهد. صحت و یادآوری نیز بالا هستند که به‌ترتیب برابر با ۰/۹۲۳۳ و ۰/۹۱۵۷ هستند. دقت متقابل برابر ۰/۹۱۰۳ است که نشان‌دهنده عملکرد پایدار این مدل است.
- کلاس ۲: این کلاس نیز عملکرد بسیار خوبی با AUC برابر با ۰/۹۸۱۸ و F1-score برابر با ۰/۹۲۸۳ دارد.
- کلاس ۳: این مدل بهترین عملکرد را با AUC مقدار ۰/۹۹۹۷ نشان می‌دهد که نشان‌دهنده دقت بسیار بالای این الگوریتم برای این کلاس است.

۲. جنگل تصادفی

جنگل تصادفی نیز عملکرد خوبی از خود نشان داده است. دقت برابر با ۰/۹۱۸۰ است که نشان‌دهنده پیش‌بینی‌های دقیق مدل است. دقت متقابل برابر با ۰/۸۸۰۷ است که نشان می‌دهد مدل جنگل تصادفی نیز تعمیم‌پذیری خوبی دارد، اگرچه کمی پایین‌تر از ماشین بردار پشتیبان است. این تفاوت‌ها نشان می‌دهد که جنگل تصادفی ممکن است کمی نسبت به تغییرات در داده‌ها حساس‌تر باشد، اما همچنان یک مدل قدرتمند است.

- کلاس ۱: با AUC برابر با ۰/۹۷۹۲ و F1-score برابر با ۰/۸۷۶۸، کمی پایین‌تر از ماشین بردار پشتیبان قرار دارد؛ اما همچنان عملکرد بسیار خوبی دارد. دقت متقابل برابر با ۰/۸۸۰۷ است.
- کلاس ۲: این کلاس نیز با AUC برابر با ۰/۹۷۹۶ و F1-score برابر با ۰/۸۹۱۰ عملکرد خوبی دارد.
- کلاس ۳: AUC برابر با ۰/۹۹۹۵ است که مشابه ماشین بردار پشتیبان، نشان‌دهنده عملکرد عالی این الگوریتم برای این کلاس است.

۳. درخت تصمیم

درخت تصمیم عملکرد متوسطی دارد. دقت برابر با ۰/۷۰۳۴ است که نشان می‌دهد مدل در پیش‌بینی‌های خود دقت متوسطی دارد. دقت متقابل ۰/۶۶۰۲ نیز نشان می‌دهد که این مدل نسبت به ماشین بردار پشتیبان و جنگل تصادفی پایداری کمتری دارد و ممکن است به تغییرات در داده‌ها حساس‌تر باشد.

- کلاس ۱: عملکرد متوسطی دارد با AUC برابر با ۰/۸۲۲۱ و F1-score برابر با ۰/۶۶۱۵. دقت کلی برابر با ۰/۶۶۰۲ نشان‌دهنده نوسان در نتایج است.

- کلاس ۲: عملکرد مشابهی با AUC برابر با ۰/۸۳۱۴ و F1-score برابر با ۰/۶۴۷۷ دارد.
- کلاس ۳: AUC برابر با ۰/۹۳۹۹ است که همچنان پایین‌تر از جنگل تصادفی و ماشین بردار پشتیبان است.

۴. رگرسیون لجستیک

رگرسیون لجستیک ضعیف‌ترین عملکرد را در میان این مدل‌ها دارد. دقت برابر با ۰/۴۰۳۴ است که نشان‌دهنده دقت پایین مدل در پیش‌بینی‌ها است. دقت متقابل ۰/۴۰۰۲ نیز این نتیجه را تأیید می‌کند. این نتایج نشان می‌دهد که رگرسیون لجستیک برای این مسئله خاص مناسب نیست و احتمالاً نمی‌تواند به‌خوبی الگوهای موجود در داده‌ها را تشخیص دهد.

- کلاس ۱: این مدل عملکرد ضعیفی با AUC برابر با ۰/۵۹۴۰ و F1-score برابر با ۰/۳۹۸۶ نشان می‌دهد.
- کلاس ۲: AUC و F1-score پایین‌تر از حد قابل قبول هستند که نشان‌دهنده عملکرد ضعیف این مدل برای این کلاس است.
- کلاس ۳: AUC برابر با ۰/۵۹۹۹ و F1-score برابر با ۰/۴۵۲۲ است که نشان‌دهنده کارایی پایین این الگوریتم است.

۵. بیز ساده

بیز ساده نیز عملکرد ضعیفی مشابه با رگرسیون لجستیک دارد. دقت برابر با ۰/۳۹۵۷ و دقت متقابل برابر با ۰/۳۹۳۹ نشان‌دهنده ناتوانی این مدل در پیش‌بینی‌های صحیح است.

- کلاس ۱: عملکرد ضعیف با AUC برابر با ۰/۵۵۸۷ و F1-score برابر با ۰/۴۳۲۷ دارد.
- کلاس ۲: با AUC برابر با ۰/۵۵۹۱ و F1-score برابر با ۰/۱۸۹۰، عملکرد بسیار ضعیفی دارد.
- کلاس ۳: AUC برابر با ۰/۵۸۳۲ و F1-score برابر با ۰/۴۷۰۷ است که نشان‌دهنده کارایی پایین این مدل است.

۶. k نزدیک‌ترین همسایه (KNN)

k نزدیک‌ترین همسایه عملکرد متوسطی دارد. دقت برابر با ۰/۸۱۰۱ نشان‌دهنده عملکرد خوب، ولی نه عالی این مدل است. دقت متقابل برابر با ۰/۷۸۲۳ نیز نشان می‌دهد که این مدل پایداری نسبتاً خوبی دارد. این الگوریتم به تعداد همسایه‌ها و ساختار داده‌ها بسیار حساس است و ممکن است به‌دلیل حساسیت به نویز در داده‌ها عملکردش پایین‌تر از ماشین بردار پشتیبان و جنگل تصادفی باشد.

- کلاس ۱: عملکرد متوسطی با AUC برابر با ۰/۸۸۳۹ و F1-score برابر با ۰/۶۹۵۱ نشان می‌دهد.
- کلاس ۲: با AUC برابر با ۰/۹۱۹۱ و F1-score برابر با ۰/۷۷۴۷ عملکرد خوبی دارد، اگرچه همچنان پایین‌تر از ماشین بردار پشتیبان و جنگل تصادفی است.
- کلاس ۳: این مدل نیز با AUC برابر با ۰/۹۹۰۵ و F1-score برابر با ۰/۹۴۰۷ عملکرد بسیار خوبی دارد.


ماشین بردار پشتیبان و جنگل تصادفی، به‌طور کلی بهترین عملکرد را در این پژوهش نشان داده‌اند؛ به‌ویژه برای کلاس ۳ که AUC آن‌ها نزدیک به ۱ است. این دو الگوریتم می‌توانند گزینه‌های مناسبی برای مدل‌سازی نهایی باشند. درخت تصمیم و k نزدیک‌ترین همسایه عملکرد متوسطی داشتند که ممکن است در شرایط خاصی مفید باشند؛ اما به اندازه ماشین بردار پشتیبان و جنگل تصادفی قوی نیستند. رگرسیون لجستیک و بیز شاده عملکرد بسیار ضعیفی داشتند و برای این مسئله مناسب نیستند. با توجه به نتایج، ماشین بردار پشتیبان و جنگل تصادفی به‌عنوان بهترین الگوریتم‌ها برای این مجموعه داده‌ها انتخاب می‌شوند. نتایج در جدول ۸ مشاهده می‌شود.

جدول ۸. نتایج ارزیابی الگوریتم‌ها

الگوریتم	دقت	دقت متقابل	کلاس	صحت	بازخوانی	F1-score	AUC
SVM	۰/۹۴۴۴	۰/۹۱۰۳	۱	۰/۹۲۳۳	۰/۹۱۵۷	۰/۹۱۹۵	۰/۹۷۷۴
			۲	۰/۹۲۷۵	۰/۹۲۹۰	۰/۹۲۸۳	۰/۹۸۱۸
			۳	۰/۹۸۲۰	۰/۹۸۸۴	۰/۹۸۵۲	۰/۹۹۹۷
RF	۰/۹۱۸۰	۰/۸۸۰۷	۱	۰/۹۳۷۹	۰/۸۲۳۱	۰/۸۷۶۸	۰/۹۷۹۲
			۲	۰/۸۴۹۰	۰/۹۳۷۳	۰/۸۹۱۰	۰/۹۷۹۶
			۳	۰/۹۷۵۷	۰/۹۹۳۴	۰/۹۸۴۵	۰/۹۹۹۵
DT	۰/۷۰۳۴	۰/۶۶۰۲	۱	۰/۶۹۴۵	۰/۶۳۱۴	۰/۶۶۱۵	۰/۸۲۲۱
			۲	۰/۶۲۲۵	۰/۶۷۴۹	۰/۶۴۷۷	۰/۸۳۱۴
			۳	۰/۷۹۸۴	۰/۸۰۳۶	۰/۸۰۱۰	۰/۹۳۹۹
LR	۰/۴۰۳۴	۰/۴۰۰۲	۱	۰/۴۱۳۱	۰/۳۸۵۱	۰/۳۹۸۶	۰/۵۹۴۰
			۲	۰/۴۰۰۴	۰/۳۰۲۰	۰/۳۴۴۳	۰/۵۶۱۰
			۳	۰/۳۹۸۲	۰/۵۲۳۱	۰/۴۵۲۲	۰/۵۹۹۹
NB	۰/۳۹۵۷	۰/۳۹۲۹	۱	۰/۳۸۷۹	۰/۴۸۹۳	۰/۴۳۲۷	۰/۵۵۸۷
			۲	۰/۴۱۸۱	۰/۱۲۲۱	۰/۱۸۹۰	۰/۵۵۹۱
			۳	۰/۳۹۷۹	۰/۵۷۵۹	۰/۴۷۰۷	۰/۵۸۳۲
KNN	۰/۸۱۰۱	۰/۷۸۲۳	۱	۰/۸۱۳۷	۰/۶۰۶۶	۰/۶۹۵۱	۰/۸۸۳۹
			۲	۰/۷۲۷۵	۰/۸۲۸۴	۰/۷۷۴۷	۰/۹۱۹۱
			۳	۰/۸۹۲۰	۰/۹۹۵۰	۰/۹۴۰۷	۰/۹۹۰۵

برای ارزیابی دقت پیش‌بینی الگوریتم‌های استفاده شده، از مساحت زیر منحنی AUC-ROC استفاده شده است. منحنی ROC به صورت گرافیکی عملکرد مدل طبقه‌بندی را در آستانه‌های مختلف نشان می‌دهد و رابطه بین نرخ مثبت واقعی و نرخ مثبت کاذب را به تصویر می‌کشد که در واقع توانایی طبقه‌بند برای تمایز بین کلاس‌ها را نشان می‌دهد. AUC بالاتر بیانگر عملکرد بهتر مدل است، به‌طوری که قادر به تفکیک مؤثر کلاس‌ها است. شکل ۵ منحنی‌های


ROC را برای الگوریتم‌های مختلف نمایش می‌دهد. همان‌طور که مشاهده می‌شود، الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان نتایج رضایت‌بخشی ارائه داده‌اند.



شکل ۵. نمودار ROC

رگرسیون لجستیک یک مدل خطی است و به خوبی نمی‌تواند روابط غیرخطی پیچیده بین متغیرهای ورودی و خروجی را مدل کند. در صورتی که داده‌های ریسک عملیاتی دارای تعاملات پیچیده و غیرخطی است، این مدل نمی‌تواند به درستی کلاس‌ها را از هم تفکیک کند. بیز ساده بر این فرض استوار است که ویژگی‌های ورودی به صورت شرطی مستقل از یکدیگرند. در دنیای واقعی، این فرض به ندرت برقرار است، به ویژه در مسائل مربوط به ریسک، جایی که متغیرها اغلب به شدت به یکدیگر وابسته‌اند که این مسئله باعث کاهش توانایی مدل در تمایز کلاس‌ها می‌شود. مدل‌های پیچیده‌تر مانند SVM و RF قادرند با استفاده از تکنیک‌های یادگیری غیرخطی، تصمیمات بسیار بهتری بگیرند. در حالی که مدل‌هایی مثل LR و NB، مرزهای تصمیم‌گیری ساده‌تری دارند و این موضوع می‌تواند باعث کاهش دقت شود. مقادیر AUC پایین NB و LR نشان می‌دهد که این مدل‌ها در تشخیص کلاس‌ها کارایی پایینی دارند و تقریباً عملکردی نزدیک به حدس تصادفی دارند. SVM و RF از یادگیری ویژگی‌های پیچیده داده‌ها بهره می‌برند، در حالی که NB و LR فقط الگوهای ساده و خطی را می‌توانند یاد بگیرند. در مسائلی مانند ریسک عملیاتی، تصمیم‌گیری معمولاً به عوامل مختلفی بستگی دارد که به طور پیچیده‌ای با یکدیگر تعامل دارند و این ویژگی‌ها را نمی‌توان به راحتی با یک مدل ساده مدل‌سازی کرد.

ماتریس درهم‌ریختگی برای مدل مورد نظر رسم شد. عناصر پرنرنگ، کلاس‌هایی هستند که مدل به درستی پیش‌بینی کرده است. در شکل ۶ ماتریس درهم‌ریختگی را برحسب ۶ الگوریتم بیان شده قابل نمایش است.



شکل ۶. نتایج ماتریس درهم‌ریختگی

نتیجه‌گیری و پیشنهادها

این پژوهش به بررسی نقش الگوریتم‌های یادگیری ماشین در بهبود مدیریت ریسک‌های عملیاتی در بانک‌ها پرداخته است. تحلیل‌های صورت گرفته نشان می‌دهد که این الگوریتم‌ها توانسته‌اند دقت پیش‌بینی سطوح ریسک‌های عملیاتی را به‌طور چشمگیری افزایش دهند. نتایج پژوهش به‌وضوح نشان می‌دهد که الگوریتم‌های یادگیری ماشین می‌توانند در تحلیل داده‌های پیچیده و حجیم بانکی، به شناسایی الگوهای غیرمعمول و پیش‌بینی ریسک‌ها به‌طور کارآمدی کمک کنند. یکی از نکات قوت این پژوهش، تأکید بر قابلیت الگوریتم‌های یادگیری ماشین در ارائه پیش‌بینی‌های دقیق‌تر ریسک عملیاتی در محیط‌های اقتصادی و مالی است. این ویژگی به بانک‌ها این امکان را می‌دهد استراتژی‌های مناسب‌تری را برای مدیریت ریسک‌های عملیاتی تدوین کنند. علاوه‌براین، به‌کارگیری این الگوریتم‌ها می‌تواند به کاهش شایان توجه هزینه‌های مربوط به مدیریت ریسک و بهبود تصمیم‌گیری‌های استراتژیک منجر شود. بنابراین، این فناوری‌ها نه تنها به بهبود کارایی مدیریتی ریسک کمک می‌کنند، بلکه باعث ارتقای کلی عملکرد بانک‌ها در زمینه مدیریت مالی و عملیاتی نیز خواهند شد. به‌طور کلی، یافته‌های این پژوهش بر اهمیت و کارایی الگوریتم‌های یادگیری ماشین در مدیریت ریسک‌های عملیاتی تأکید می‌کند و نشان می‌دهد که این تکنولوژی‌ها می‌توانند به‌عنوان ابزارهای کلیدی برای بهبود استراتژی‌های مدیریت ریسک در بانک‌ها استفاده شوند. با توجه به تحولات سریع در حوزه فناوری اطلاعات و داده‌های بزرگ، استمرار در بررسی و بهره‌برداری از این الگوریتم‌ها می‌تواند به موفقیت و پایداری بیشتر در صنعت بانکداری کمک شایانی کند.

همان‌طور که بیان شد، هدف از این پژوهش پیش‌بینی ریسک عملیاتی با استفاده از الگوریتم‌های یادگیری ماشین بود؛ اما در پژوهش‌های دیگری همچون اکبری و یزدانیان (۱۴۰۲) با استفاده از الگوریتم‌های یادگیری ماشین، آستانه مناسب برای داده‌های شدت زیان عملیاتی برآورد و طبقه‌بندی شده است، در پژوهش پنا و همکاران (۲۰۲۱)، از مدل یادگیری عمیق کانولوشنال فازی، برای تخمین حداکثر ارزش در معرض خطر ریسک عملیاتی با سطح اطمینان ۹۹/۹ درصد استفاده شده است. در پژوهش ژو و همکاران (۲۰۲۰) با استفاده از الگوریتم‌های یادگیری ماشین نیمه‌نظارت شده، ریسک‌های عملیاتی بر اساس اخبار مالی طبقه‌بندی شده است. جناس و لوریشین^۱ (۲۰۱۲) با استفاده از الگوریتم‌های بیز ساده، k نزدیک‌ترین همسایه و درخت تصمیم، مدلی برای بهبود تشخیص تقلب کارت اعتباری ارائه دادند. همچنین شارما و چودوری^۲ (۲۰۱۶) توانستند با استفاده از الگوریتم‌های یادگیری بدون نظارت، مدلی برای شناسایی اقدام‌های متقلبانه در زمینه کارت‌های اعتباری و پول‌شویی انجام دهند. با توجه به آنچه بیان شد، پژوهش حاضر با پژوهش‌های انجام‌شده قبل تفاوت دارد. در این پژوهش، پیش‌بینی ریسک عملیاتی انجام شده است؛ اما در پژوهش‌های دیگر تخمین سرمایه پوششی ریسک عملیاتی و حداکثر ارزش در معرض ریسک، طبقه‌بندی رویدادهای ریسک عملیاتی، شناسایی اقدامات متقلبانه و بهبود تشخیص تقلب با استفاده از الگوریتم‌های یادگیری ماشین صورت گرفته است.

1. Pun & Lawryshyn

2. Sharma & Choudhury

تحقیقات آینده می‌توانند روی توسعه الگوریتم‌های پیش‌بینی پیشرفته‌تر و بهینه‌سازی مدل‌های یادگیری ماشین تمرکز کنند. به‌ویژه، الگوریتم‌های جدیدی که توانایی بیشتری در تحلیل داده‌های غیرساختاریافته و پیچیده دارند، می‌توانند به بهبود دقت پیش‌بینی و شناسایی ریسک‌های عملیاتی کمک کنند. با توجه به اینکه داده‌های مربوط به ریسک‌های عملیاتی می‌توانند از منابع مختلفی مانند سیستم‌های مالی، عملیاتی و داده‌های خارجی جمع‌آوری شوند، پیشنهاد می‌شود که بهبود روش‌های یکپارچه‌سازی و تجزیه و تحلیل داده‌های چندمنبعی در کانون توجه قرار گیرد. علاوه‌براین، یکی از چالش‌های مهم در مدیریت داده‌های بانکی، وجود داده‌های گم‌شده و ناهماهنگی‌های موجود در داده‌هاست که می‌تواند دقت مدل‌های یادگیری ماشین را تحت تأثیر قرار دهد. بنابراین، تحقیقات آینده می‌توانند بر توسعه روش‌های پیشرفته برای پردازش داده‌های ناقص، بهبود تکنیک‌های جایگزینی داده‌های گم‌شده و طراحی مدل‌هایی که در برابر داده‌های نامتوازن و ناهماهنگ مقاوم‌تر باشند، تمرکز کنند. این کار می‌تواند به بهبود کیفیت تحلیل‌ها و پیش‌بینی‌های انجام‌شده کمک کند.

منابع

- استادی، بختیار؛ خزایی، سجاد و حسین‌زاده کاشان، علی (۱۳۹۷). ارزیابی ریسک عملیاتی با استفاده از روش استنتاج بیزی و با در نظر گرفتن ترکیب منابع داده‌ای و فرض وابستگی بین نظرات کارشناسان و داده‌های زیان داخلی. *راهبرد مدیریت مالی*، ۱۶(۱)، ۵۳-۷۲.
- اکبری، مهدی و یزدانیان، احمدرضا (۱۴۰۲). یادگیری ماشین در تخمین سرمایه پوششی ریسک عملیاتی بانک‌ها با رویکرد توزیع زیان. *چشم‌انداز مدیریت مالی*، ۱۳(۴۲)، ۹-۳۴.
- باجلان، سعید؛ فلاح پور، سعید و رئیسی، سارا (۱۴۰۳). بهینه‌سازی پرتفوی اعتباری بانک‌ها با استفاده از رویکرد اکچوئری و شبکه عصبی مصنوعی. *تحقیقات مالی*، ۲۶(۳)، ۷۱۰-۷۳۳.
- تهرانی، رضا؛ سراج، مصطفی؛ فروش باستانی، علی و فلاح پور، سعید (۱۳۹۹). ارزیابی اثر ریسک سیستمی بخش بانکی بر عملکرد اقتصاد کلان ایران. *تحقیقات مالی*، ۲۲(۳)، ۲۹۷-۳۱۹.
- خوش سیماء، رضا و شهیکی تاش، محمدنبی (۱۳۹۱). تأثیر ریسک‌های اعتباری، عملیاتی و نقدینگی بر کارایی نظام بانکی ایران. *فصلنامه برنامه‌ریزی و بودجه*، ۱۷(۴)، ۶۹-۹۵.
- رحیمی باغی، علی؛ عرب صالحی، مهدی و واعظ برزانی، محمد (۱۳۹۸). ارزیابی ریسک سیستمی در نظام مالی کشور با استفاده از روش شبکه علیت گرنجر. *تحقیقات مالی*، ۲۱(۱)، ۱۲۱-۱۴۲.
- صادقی مقدم، محمدرضا؛ مهرگان، محمد رضا و بهرام بیگ، نیلا (۱۴۰۳). کاهش هزینه کشف تقلب در تراکنش‌های کارت‌های اعتباری: با رویکرد هم‌جوشی اطلاعات. *تحقیقات مالی*، ۲۷(۲)، ۳۲۴-۳۵۳.
- طالبی، محمد؛ کاوند، مجتبی و حسین‌پور، محمد (۱۳۹۰). تحلیل و رتبه‌بندی ریسک‌های عملیاتی در بانکداری اسلامی؛ مطالعه موردی: بانکداری بدون ربا در ایران. *اقتصاد اسلامی*، ۱۱(۴۴)، ۱۵۷-۱۸۴.

- قربانی، رامین؛ کردستانی، غلامرضا؛ حقیقت، حمید؛ قائمی، محمدحسین و عزیزمحمود، حمید (۱۳۹۹). ارائه مدلی برای ارزیابی اثربخشی مدیریت ریسک در صنعت بانکداری. *تحقیقات مالی*، ۲۲(۴)، ۴۹۶-۵۲۰.
- مصطفائی دولت آباد، خدیجه؛ آذر، عادل و مقبل باعرض، عباس (۱۳۹۷). شناسایی و تحلیل ریسک‌های عملیاتی با استفاده از نگاشت شناختی فازی. *نشریه مدیریت دارایی و تأمین مالی*، ۶(۴)، ۱-۱۸.
- نادری، حامد و رستگار، محمدعلی (۱۴۰۱). به‌کارگیری روش فراترکیب در روش‌شناسی مدیریت ریسک عملیاتی بانکی. *مدیریت دارایی و تأمین مالی*، ۱۰(۴)، ۱۱۵-۱۳۲.
- نصرتی، هاشم و پاکیزه، کامران (۱۳۹۳). تخمین ذخیره سرمایه ریسک عملیاتی در صنعت بانکداری. *مهندسی مالی و مدیریت اوراق بهادار*، ۵(۲۰)، ۱-۲۶.

References

- Abdymomunov, A., Curti, F. & Mihov, A. (2020). US banking sector operational losses and the macroeconomic environment. *Journal of Money, Credit and Banking*, 52(1), 115 - 144.
- Afonso, G., Curti, F. & Mihov, A. (2019). *Coming to terms with operational risk* (No. 20190107). Federal Reserve Bank of New York.
- Afroz, S., Brennan, M. & Greenstadt, R. (2012, May). Detecting hoaxes, frauds, and deception in writing style online. In *2012 IEEE symposium on security and privacy* (pp. 461-475). IEEE.
- Akbari, M. & Yazdani, A. (2023). Machine learning in estimating operational risk coverage capital of banks with a loss distribution Approach. *Financial Management Perspective*, 13(42), 9-34. doi: 10.48308/jfmp.2023.103948. (in Persian)
- Bajalan, S. , Fallahpour, S. and Raeesi, S. (2024). Bank's Credit Portfolio Optimization Using Actuarial Approach and Artificial Neural Networks. *Financial Research Journal*, 26(3), 710-733. (in Persian)
- Bank for International Settlements (2004). *Basel II: International Convergence of Capital Measurement and Capital Standards: a Revised Framework*. <https://www.bis.org/publ/bcbs107.htm> (06 2004).
- Bank for International Settlements (2016). *Standardised measurement approach for operational risk - consultative document*.
- Barakat, A. & Hussainey, K. (2013). Bank governance, regulation, supervision, and risk reporting: Evidence from operational risk disclosures in European banks. *International Review of Financial Analysis*, 30, 254-273.
- Basel Committee on Banking Supervision (2006). *International convergence of capital measurement and capital standards: A Revised Framework - Comprehensive Version*. Bank of International Sett.
- Bouveret, A. (2018). *Cyber risk for the financial sector: A framework for quantitative assessment*. International Monetary Fund.

- Cantarella, M., Fraccaroli, N. & Volpe, R. (2023). Does fake news affect voting behaviour?. *Research Policy*, 52(1), 104628.
- Committee of Sponsoring Organizations of the Treadway Commission (COSO). (2017). *Enterprise Risk Management: Integrating with Strategy and Performance*. New York, NY: COSO.
- Crisanto, J. C. & Prenio, J. (2017). *Regulatory approaches to enhance banks' cyber-security frameworks*. Bank for International Settlements, Financial Stability Institute.
- Crouhy, M., Galai, D. & Mark, R. (1998). Key steps in building consistent operational risk measurement and management. *Operational Risk and Financial Institutions, London: Risk Books*, 17(3), 45-62.
- Drew, J. M. & Farrell, L. (2018). Online victimization risk and self-protective strategies: Developing police-led cyber fraud prevention programs. *Police Practice and Research*, 19(6), 537-549.
- Garg, A., Lilhore, U. K., Ghosh, P., Prasad, D. & Simaiya, S. (2021, August). Machine learning-based model for prediction of student's performance in higher education. In *2021 8th international conference on signal processing and integrated networks (SPIN)* (pp. 162-168). IEEE.
- Ghorbani, R., Kordestani, G., Haghighat, H., Ghaemi, M. H. and Azizmohammadlou, H. (2021). Developing a Model for Evaluating the Effectiveness of Risk Management in the Banking Industry. *Financial Research Journal*, 22(4), 496-520. (in Persian)
- González-Carrasco, I., Jiménez-Márquez, J. L., López-Cuadrado, J. L. & Ruiz-Mezcua, B. (2019). Automatic detection of relationships between banking operations using machine learning. *Information Sciences*, 485, 319-346.
- Goutte, C. & Gaussier, E. (2005, March). A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In *European conference on information retrieval* (pp. 345-359). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Guo, B., Ding, Y., Yao, L., Liang, Y. & Yu, Z. (2020). The future of false information detection on social media: New perspectives and trends. *ACM Computing Surveys (CSUR)*, 53(4), 1-36. doi: 10.1145/3393880
- Hoffman, D.G. (2002). *Managing Operational Risk: 20 Firmwide Best Practice Strategies*, John Wiley & Sons.
- Jabbar, M. A., Deekshatulu, B. L. & Chandra, P. (2016). Intelligent heart disease prediction system using random forest and evolutionary approach. *Journal of network and innovative computing*, 4, 10-10.
- Khosh Sima, R. & Shahiki Tash, M. (2013). The impact of credit, operational and liquidity risks on the efficiency of Iran's banking system. *Planning and Budgeting*, 17(4), 69-95. (in Persian)

- Khrestina, M. P., Dorofeev, D. I., Kachurina, P. A., Usabaliev, T. R. & Dobrotvorskiy, A. S. (2017). Development of algorithms for searching, analyzing and detecting fraudulent activities in the financial sphere.
- Liu, X., Wang, X., Su, Q., Zhang, M., Zhu, Y., Wang, Q. & Wang, Q. (2017). A hybrid classification system for heart disease diagnosis based on the RFRS method. *Computational and mathematical methods in medicine*, 2017(1), 8272091.
- Mora Valencia, A. (2010). Cuantificación del riesgo operativo en entidades financieras en Colombia. *Cuadernos de Administración*, 23(41), 185-211.
- Mora-Valencia, A. & Zapata-Jaramillo, W. (2017, July). Quantifying operational risk using the loss distribution approach (lda) model. In *Proceedings of the Seventh European Academic Research Conference on Global Business, Economics, Finance and Banking (EAR17Swiss Conference)* (pp. 0-10).
- Mostafaei, K., Azar, A. & Moghbel, A. (2018). Identification and analysis of operational risks: A fuzzy cognitive map approach. *Journal of Asset Management and Financing*, 6(4), 1-18. doi: 10.22108/amf.2018.103404.1087. (in Persian)
- Naderi, H. & Rastegar, M. A. (2022). Applying the Meta-Synthesis Method in Banking Operational Risk Management Methodology. *Journal of Asset Management and Financing*, 10(4), 115-132. <https://doi.org/10.22108/amf.2023.135765.1767>. (in Persian)
- Nosrati, H. & Pakizeh, K. (2014). Estimation of operating capital reserves in the banking industry. *Financial Engineering and Portfolio Management*, 5(20), 1-26. (in Persian)
- Ostadi, B., Khazayi, S. & Husseinzadeh Kashan, A. (2018). Operational risk Assessment using Bayesian inference with regard to the composition of data sources and the assumption of dependence between experts and internal loss data. *Financial Management Strategy*, 6(1), 53-72. (in Persian)
- Peña, A., Bonet, I., Lochmuller, C., Chiclana, F. & Góngora, M. (2018). An integrated inverse adaptive neural fuzzy system with Monte-Carlo sampling method for operational risk management. *Expert Systems with Applications*, 98, 11-26.
- Pena, A., Patino, A., Chiclana, F., Caraffini, F., Gongora, M., Gonzalez-Ruiz, J. D. & Duque-Grisales, E. (2021). Fuzzy convolutional deep-learning model to estimate the operational risk capital using multi-source risk events. *Applied Soft Computing*, 107, 107381.
- Pereira, P. & Pereira, A. (2018). Operational risk management: The basel II.
- Poongodi, M., Nguyen, T. N., Hamdi, M. & Cengiz, K. (2023). RETRACTED ARTICLE: A measurement approach using smart-IoT based architecture for detecting the COVID-19. *Neural Processing Letters*, 55(1), 877-877.
- Pun, J. & Lawryshyn, Y. (2012). Improving credit card fraud detection using a meta-classification strategy. *International Journal of Computer Applications*, 56(10), 41-46.
- Rahimi Baghi, A., ArabSalehi, M. and Vaez Barzani, M. (2019). Assessing the Systemic Risk in the Financial System of Iran using Granger Causality Network Method. *Financial Research Journal*, 21(1), 121-142. (in Persian)

- Sadeghi Moghadam, M. R. , Mehregan, M. and Bahrambeig, N. (2025). Reducing Fraud Detection Costs in Credit Card Transactions: An Information Fusion Approach. *Financial Research Journal*, 27(2), 324-353. doi: 10.22059/frj.2024.338715.1007300 (in Persian)
- Sharma, S. & Choudhury, A. R. (2016). Fraud analytics: A survey on bank fraud and fraud prediction using unsupervised learning based approach. *International Journal of Innovations in Engineering Research and Technology*, 3(3), 1-9.
- Simaiya, S., Gautam, V., Lilhore, U. K., Garg, A., Ghosh, P., Trivedi, N. K. & Anand, A. (2021, October). EEPsA: Energy efficiency priority scheduling algorithm for cloud computing. In *2021 2nd international conference on smart electronics and communication (ICOSEC)* (pp. 1064-1069). IEEE.
- Simaiya, S., Lilhore, U. K., Prasad, D. & Verma, D. K. (2021). MRI brain tumour detection & image segmentation by hybrid hierarchical K-means clustering with FCM based machine learning model. *Annals of the Romanian Society for Cell Biology*, 25(1), 88-94.
- Talebi, M., Kavand, M. & Hosseinpour, M. (2011). Analysis and ranking of operational risks in Islamic banking; Case study: Interest-free banking in Iran. *Islamic Economics*, 11(44), 157-184. (in Persian)
- Tehrani, R., Seraj, M., Foroush Bastani, A. & Fallahpour, S. (2020). Evaluation of the Effect of the Banking Sector Systemic Risk on the Macroeconomic Performance of Iran. *Financial Research Journal*, 22(3), 297-319. (in Persian)
- Tsai, C. F. & Wu, J. W. (2008). Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert systems with applications*, 34(4), 2639-2649.
- Wang, T. & Hsu, C. (2013). Board composition and operational risk events of financial institutions. *Journal of Banking & Finance*, 37(6), 2042-2051.
- Zhou, F., Qi, X., Xiao, C. & Wang, J. (2021). MetaRisk: Semi-supervised few-shot operational risk classification in banking industry. *Information Sciences*, 552, 1-16.