

Analyzing Corporate Bankruptcy Prediction Models Using Machine Learning

1. Mohammad Rezaei^{ID}: Department of IT, University of Tehran, Tehran, Iran

2. Ali Ahmadi^{ID*}: Department of Economics, University of Shiraz, Shiraz, Iran. Email: Aahmadi34@shiraz.ac.ir (Corresponding Author)

Article history



Received: 25 July 2024

Revised: 12 August 2024

Accepted: 27 August 2024

Published: 12 October 2024

Abstract:

Corporate bankruptcy prediction is a critical and complex topic in finance and management that helps prevent financial crises and aids in better decision-making regarding financial risk management. In this regard, the use of machine learning algorithms, due to their ability to process complex data and provide accurate predictions, has emerged as a modern tool in this domain. This study aims to review and compare different machine learning models for corporate bankruptcy prediction and analyze the challenges and limitations of these models. This research follows a systematic literature review method, analyzing relevant scientific articles on the use of machine learning in bankruptcy prediction. Various models, including decision trees, random forests, artificial neural networks, and support vector machines, are examined, with their accuracy and performance evaluated based on empirical data. The results indicate that more complex models, such as neural networks and boosting algorithms, perform better than simpler models like decision trees when dealing with complex and multidimensional data. However, these advanced models face challenges such as interpretability issues, the need for large datasets, and complex parameter tuning. Machine learning techniques can provide high accuracy in predicting corporate bankruptcy, but improvements are needed in addressing challenges like data imbalance, enhancing data quality, and developing more interpretable models.

Keywords: Bankruptcy prediction, Machine learning, Artificial neural networks, Decision trees, Random forests, Support vector machines.

Extended Abstract

Corporate bankruptcy prediction has become increasingly important in today's fast-paced and competitive business environment. Predicting financial distress in companies is not only crucial for the companies themselves but also for investors, creditors, and regulators, as it helps mitigate risks and prevent financial crises. Traditionally, models such as Altman's Z-Score and logistic regression have been used extensively to predict bankruptcy, primarily relying on financial ratios and historical data. However, these models have limitations in capturing non-linear relationships and adapting to complex, multidimensional data [1]. With the advancements in machine learning, more sophisticated models have emerged, allowing for better handling of such complexities and improving the accuracy of predictions.

Citation: Rezaei, M., & Ahmadi, A. (2024). Analyzing Corporate Bankruptcy Prediction Models Using Machine Learning. *Accounting, Finance and Computational Intelligence*, 1(3), 13-24.



The use of machine learning models in bankruptcy prediction has gained traction due to their ability to process large datasets, uncover hidden patterns, and adapt to different types of data. Algorithms such as decision trees, random forests, artificial neural networks (ANN), and support vector machines (SVM) are now widely used in research to predict corporate bankruptcy with higher precision [2]. Decision trees, as one of the simpler models, are easy to interpret and provide quick results, making them popular for early-stage analysis. However, they are limited in handling more complex and non-linear relationships between variables. Random forests, an extension of decision trees, address some of these limitations by combining multiple decision trees to improve accuracy and reduce the risk of overfitting [3].

Artificial neural networks are among the more advanced machine learning models used in bankruptcy prediction. Inspired by the structure of the human brain, these models are particularly effective at identifying non-linear patterns in data, making them suitable for financial datasets where relationships between variables can be complex [4]. ANNs can handle large volumes of data and improve their performance through continuous learning. However, they come with a higher computational cost and require extensive parameter tuning. Additionally, due to the complexity of their inner workings, they are often criticized for being “black boxes” as their decision-making process is not easily interpretable, which poses challenges for financial managers and decision-makers who need clear and understandable explanations [5].

Another highly regarded model in this field is the support vector machine (SVM), known for its efficiency in classifying data with clear boundaries. SVMs are particularly effective in cases where there is a need to separate two distinct groups, such as bankrupt and non-bankrupt firms. This model works by finding an optimal hyperplane that separates the data points with the largest possible margin. Studies have demonstrated that SVMs, especially when combined with kernel methods, can provide superior results in bankruptcy prediction, especially in datasets where relationships between variables are non-linear [6]. However, like ANNs, SVMs require careful tuning of parameters, and their performance can be sensitive to the choice of kernel and input data structure [3].

Despite the strong performance of these machine learning models, several challenges remain in their application to bankruptcy prediction. Data quality is one of the most significant challenges, as the accuracy of predictions heavily relies on the completeness and accuracy of the input data. Financial data can often be incomplete, inconsistent, or outdated, which can negatively impact the model’s performance [7-9]. Additionally, the issue of data imbalance is common in bankruptcy prediction since the number of bankrupt firms is usually much smaller than that of non-bankrupt firms. This imbalance can lead models to focus more on predicting non-bankrupt firms correctly, thereby reducing their accuracy in identifying companies that are actually at risk of bankruptcy. Techniques such as oversampling, undersampling, and cost-sensitive learning have been proposed to address this problem and improve the performance of machine learning models [10].

In conclusion, while machine learning models such as decision trees, random forests, ANNs, and SVMs have significantly improved the accuracy of corporate bankruptcy prediction, they also introduce new challenges. Complex models, though powerful, often lack transparency, making their results difficult to interpret for business professionals. Moreover, issues related to data quality and imbalance continue to limit the effectiveness of these models. Future research should focus on developing hybrid models that combine the strengths of multiple algorithms to enhance prediction accuracy while maintaining interpretability. Furthermore, addressing data quality issues and creating more robust methods to handle imbalanced datasets will be essential for improving the practical applicability of these models in real-world scenarios [5].

Authors’ Contributions

Authors equally contributed to this article.

Acknowledgments

Authors thank all participants who participate in this study.

Declaration of Interest

The authors report no conflict of interest.

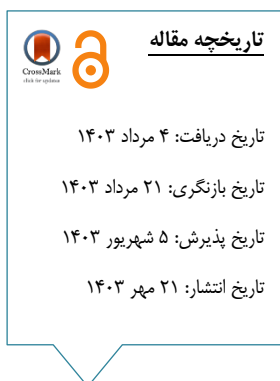
Funding

According to the authors, this article has no financial support.

Ethical Considerations

All procedures performed in this study were under the ethical standards.

تحلیل مدل‌های پیش‌بینی ورشکستگی شرکت‌ها با استفاده از یادگیری ماشین



۱. محمد رضایی*^{ID}: دانشکده آی تی، دانشگاه تهران، تهران، ایران

۲. علی احمدی*^{ID}: دانشکده اقتصاد، دانشگاه شیراز، شیراز، ایران. ایمیل: Aahmadi34@shiraz.ac.ir (نویسنده مسئول)

چکیده

پیش‌بینی ورشکستگی شرکت‌ها یکی از موضوعات مهم و پیچیده در حوزه‌های مالی و مدیریت است که می‌تواند از وقوع بحران‌های مالی جلوگیری کند و به تصمیم‌گیری بهتر در زمینه مدیریت ریسک‌های مالی کمک کند. در این راستا، استفاده از الگوریتم‌های یادگیری ماشین به دلیل توانایی آن‌ها در پردازش داده‌های پیچیده و ارائه پیش‌بینی‌های دقیق، به عنوان یکی از ابزارهای نوین در این حوزه مطرح شده است. این مطالعه به بررسی و مقایسه مدل‌های مختلف یادگیری ماشین برای پیش‌بینی ورشکستگی شرکت‌ها می‌پردازد و چالش‌ها و محدودیت‌های این مدل‌ها را تحلیل می‌کند. این مطالعه به روش مرور سیستماتیک انجام شده و مقالات علمی مرتبط با استفاده از یادگیری ماشین در پیش‌بینی ورشکستگی مورد بررسی قرار گرفته است. مدل‌های مختلف از جمله درخت تصمیم، جنگل تصادفی، شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان مورد تحلیل قرار گرفته و دقت و کارایی آن‌ها بر اساس داده‌های تجربی بررسی شده است. نتایج نشان می‌دهد که مدل‌های پیچیده‌تری مانند شبکه‌های عصبی و الگوریتم‌های تقویتی در مواجهه با داده‌های پیچیده و چندبعدی عملکرد بهتری نسبت به مدل‌های ساده‌تری همچون درخت تصمیم دارند. با این حال، این مدل‌ها به دلیل پیچیدگی بالا و نیاز به داده‌های بزرگ، با چالش‌هایی همچون عدم تفسیرپذیری آسان و نیاز به تنظیمات دقیق مواجه هستند. استفاده از یادگیری ماشین در پیش‌بینی ورشکستگی می‌تواند دقت بالایی را ارائه دهد، اما نیاز به بهبودهایی همچون مقابله با چالش‌های نامتوازن داده‌ها، بهبود کیفیت داده‌ها و توسعه مدل‌های تفسیرپذیرتر دارد.

کلیدواژه‌گان: پیش‌بینی ورشکستگی، یادگیری ماشین، شبکه‌های عصبی مصنوعی، درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان.

شیوه استناددهی: رضایی، محمد، و احمدی، علی. (۱۴۰۳). تحلیل مدل‌های پیش‌بینی ورشکستگی شرکت‌ها با استفاده از یادگیری ماشین. حسابداری، امور مالی و هوش محاسباتی، ۱(۳)، ۱۳-۲۴.



پیش‌بینی ورشکستگی شرکت‌ها یکی از موضوعات مهم و پیچیده در حوزه‌های مالی و مدیریتی است که توجه بسیاری از محققان و تحلیل‌گران را به خود جلب کرده است. این مسئله نه تنها از دیدگاه مدیریت داخلی شرکت‌ها حائز اهمیت است، بلکه از منظر سهامداران، سرمایه‌گذاران، بانک‌ها و دیگر نهادهای مالی نیز به دلیل ریسک‌های قابل توجهی که ورشکستگی شرکت‌ها می‌تواند به همراه داشته باشد، مورد توجه قرار دارد. شرکت‌ها، به‌ویژه در محیط‌های پویا و رقابتی، همواره در معرض خطر ورشکستگی قرار دارند که می‌تواند ناشی از عوامل مختلفی همچون مدیریت ضعیف، تغییرات ناگهانی در بازار، رکود اقتصادی یا سایر عوامل خارجی باشد. در این راستا، مدل‌های پیش‌بینی ورشکستگی به‌عنوان ابزاری قدرتمند برای تحلیل وضعیت مالی شرکت‌ها و ارائه‌ی اخطارهای اولیه در مورد احتمال ورشکستگی مطرح شده‌اند [2].

در طی دهه‌های اخیر، مدل‌های مختلفی برای پیش‌بینی ورشکستگی شرکت‌ها توسعه یافته‌اند. یکی از اولین و پرکاربردترین مدل‌های پیش‌بینی ورشکستگی، مدل Z آلتمن بود که در دهه ۱۹۶۰ معرفی شد و به طور گسترده‌ای در سراسر جهان مورد استفاده قرار گرفت. این مدل بر مبنای تحلیل نسبت‌های مالی شرکت‌ها طراحی شد و توانست به عنوان یکی از موفق‌ترین مدل‌های پیش‌بینی ورشکستگی شناخته شود [1]. با وجود اینکه مدل آلتمن در بسیاری از موارد عملکرد قابل قبولی ارائه داد، اما محدودیت‌هایی نظیر عدم توجه به عوامل غیرمالی و تغییرات در محیط کسب‌وکار داشت. این محدودیت‌ها باعث شد تا محققان به دنبال توسعه مدل‌های پیشرفته‌تری برای پیش‌بینی ورشکستگی شرکت‌ها باشند. از دهه ۱۹۸۰ به بعد، با پیشرفت فناوری‌های اطلاعاتی و ظهور تکنیک‌های یادگیری ماشین، محققان شروع به استفاده از این ابزارهای جدید برای پیش‌بینی دقیق‌تر و سریع‌تر ورشکستگی شرکت‌ها کردند. یادگیری ماشین به‌عنوان یکی از حوزه‌های رو به رشد در علم داده، قادر است حجم زیادی از داده‌های مالی و غیرمالی را پردازش کرده و الگوهای پیچیده‌ای را برای پیش‌بینی ورشکستگی استخراج کند [11]. این تکنیک‌ها به ویژه در محیط‌هایی که داده‌های مالی به طور مداوم تغییر می‌کنند و پیچیدگی بالایی دارند، می‌توانند ارزشمند باشند.

یادگیری ماشین با استفاده از الگوریتم‌های مختلفی همچون درخت تصمیم، شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان و الگوریتم‌های تقویتی، به محققان این امکان را می‌دهد که مدل‌های پیش‌بینی ورشکستگی را با دقت بالاتری نسبت به مدل‌های سنتی توسعه دهند. به عنوان مثال، استفاده از شبکه‌های عصبی مصنوعی در مدل‌های پیش‌بینی ورشکستگی به دلیل توانایی آنها در یادگیری الگوهای غیرخطی و پیچیده در داده‌ها، بسیار مورد توجه قرار گرفته است [4]. همچنین، الگوریتم‌های ماشین بردار پشتیبان به دلیل دقت بالایی که در دسته‌بندی داده‌های پیچیده دارند، در چندین مطالعه برای پیش‌بینی ورشکستگی شرکت‌ها استفاده شده‌اند [3].

یکی از چالش‌های اساسی در پیش‌بینی ورشکستگی شرکت‌ها با استفاده از یادگیری ماشین، مواجهه با داده‌های نامتوازن است. در بسیاری از موارد، تعداد شرکت‌های ورشکسته نسبت به شرکت‌های غیرورشکسته بسیار کمتر است، که این مسئله می‌تواند باعث کاهش دقت مدل‌های پیش‌بینی شود. برای مقابله با این مشکل، تکنیک‌های مختلفی همچون نمونه‌برداری مجدد (Oversampling) یا استفاده از الگوریتم‌های حساس به هزینه پیشنهاد شده است که توانایی مدل را در پیش‌بینی دقیق‌تر موارد نادر ورشکستگی افزایش می‌دهد [7-9]. این تکنیک‌ها با تنظیم نحوه آموزش مدل‌ها، به آنها کمک می‌کنند تا عملکرد بهتری در پیش‌بینی موارد نادر داشته باشند.

با وجود این پیشرفت‌ها، هنوز هم چالش‌های بسیاری در حوزه پیش‌بینی ورشکستگی شرکت‌ها با استفاده از یادگیری ماشین وجود دارد. یکی از این چالش‌ها، پیچیدگی بالای الگوریتم‌ها و نیاز به داده‌های کیفی و متنوع برای آموزش مدل‌ها است. بسیاری از مدل‌های یادگیری ماشین به داده‌های مالی شرکت‌ها متکی هستند، در حالی که داده‌های غیرمالی همچون مدیریت شرکت، وضعیت بازار و حتی عوامل روانی می‌توانند نقش مهمی در پیش‌بینی ورشکستگی ایفا کنند. به همین دلیل، تحقیقات اخیر بر ترکیب داده‌های مالی و غیرمالی در مدل‌های یادگیری ماشین برای افزایش دقت پیش‌بینی تمرکز کرده‌اند [10].

هدف اصلی این پژوهش بررسی و تحلیل مدل‌های مختلف یادگیری ماشین در پیش‌بینی ورشکستگی شرکت‌ها است. این پژوهش با مرور ادبیات موجود، تلاش می‌کند تا عملکرد مدل‌های مختلف را مقایسه کرده و نقاط قوت و ضعف هر یک را شناسایی کند. پرسش اصلی که این پژوهش در پی پاسخ به آن است این است که چگونه می‌توان از یادگیری ماشین برای پیش‌بینی دقیق‌تر ورشکستگی شرکت‌ها استفاده کرد و کدام مدل‌ها بهترین عملکرد را در شرایط مختلف ارائه می‌دهند. همچنین، در این پژوهش به چالش‌ها و محدودیت‌های استفاده از یادگیری ماشین در پیش‌بینی ورشکستگی پرداخته خواهد شد و راهکارهایی برای بهبود این مدل‌ها پیشنهاد می‌شود.

نتایج حاصل از این پژوهش می‌تواند به شرکت‌ها و سرمایه‌گذاران کمک کند تا تصمیمات بهتری در مورد مدیریت ریسک مالی و سرمایه‌گذاری‌های خود اتخاذ کنند. همچنین، با توجه به اهمیت پیش‌بینی ورشکستگی در دوران رکود اقتصادی و نوسانات بازار، این مدل‌ها می‌توانند به عنوان ابزاری کارآمد برای مقابله با ریسک‌های مالی مورد استفاده قرار گیرند. در نهایت، این پژوهش به دنبال ارائه‌ی نقشه‌ی راهی برای تحقیقات آینده در زمینه‌ی استفاده از یادگیری ماشین برای پیش‌بینی ورشکستگی شرکت‌ها است [6].

روش پژوهش و مواد

روش مطالعه مورد استفاده در این پژوهش، مرور نظام‌مند ادبیات است. برای جمع‌آوری داده‌های لازم، مقالات علمی معتبر از پایگاه‌های اطلاعاتی شناخته شده نظیر Google Scholar، ScienceDirect، IEEE Xplore و PubMed مورد بررسی قرار گرفتند. کلمات کلیدی مورد استفاده برای جستجوی مقالات شامل "پیش‌بینی ورشکستگی"، "مدل‌های یادگیری ماشین"، "ورشکستگی شرکت‌ها"، و "پیش‌بینی مالی" بود. پس از جستجوی اولیه، مقالات انتخاب شده بر اساس معیارهای خاصی نظیر ارتباط موضوعی، جدید بودن، و میزان ارجاعات مورد بررسی دقیق قرار گرفتند.

در این مطالعه، تمرکز اصلی بر روی مدل‌های یادگیری ماشین است که به طور خاص برای پیش‌بینی ورشکستگی شرکت‌ها به کار گرفته شده‌اند. این مدل‌ها شامل الگوریتم‌های مختلفی مانند درخت تصمیم، جنگل تصادفی، ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی و الگوریتم‌های تقویتی هستند. مقالات انتخاب‌شده شامل توضیحات دقیق درباره این مدل‌ها، نحوه آموزش و ارزیابی آن‌ها، و داده‌های تجربی مورد استفاده در آن‌ها بودند. با تحلیل این مقالات، نقاط قوت و ضعف هر مدل به دقت مورد بررسی قرار گرفت. در فرآیند تحلیل، معیارهای مختلفی برای ارزیابی کارایی مدل‌های پیش‌بینی ورشکستگی مدنظر قرار گرفتند. این معیارها شامل دقت مدل، حساسیت، ویژگی (Specificity)، و معیارهای دیگری مانند ماتریس درهم‌ریختگی، منحنی ROC و AUC بودند که برای ارزیابی مدل‌های یادگیری ماشین به کار گرفته شدند. مقایسه این مدل‌ها بر اساس این معیارها و با توجه به داده‌های تجربی موجود در مقالات پیشین انجام شد.

به عنوان بخشی از روش‌شناسی، چالش‌های کلیدی پیش‌روی مدل‌های یادگیری ماشین در پیش‌بینی ورشکستگی نیز مورد بررسی قرار گرفت. این چالش‌ها شامل مشکلات مرتبط با کیفیت داده‌ها، عدم توازن در داده‌ها، پیچیدگی الگوریتم‌ها، و تاثیر عوامل خارجی اقتصادی و مالی بر دقت پیش‌بینی مدل‌ها بود. تحلیل این چالش‌ها بر اساس مقالاتی انجام شد که به طور مستقیم به مشکلات موجود در پیش‌بینی ورشکستگی با استفاده از یادگیری ماشین پرداخته بودند. در نهایت، نتایج حاصل از تحلیل‌ها و بررسی‌ها به شکل مقایسه‌ای ارائه خواهد شد و به شناسایی نقاط ضعف و قوت مدل‌های یادگیری ماشین در این حوزه کمک خواهد کرد. این بخش از مطالعه به گونه‌ای طراحی شده است که بتواند مسیرهای بهبود برای تحقیقات آینده در حوزه پیش‌بینی ورشکستگی با استفاده از یادگیری ماشین را نشان دهد.

مبانی نظری و پیشینه پژوهش

ورشکستگی شرکت‌ها یکی از پدیده‌های پیچیده اقتصادی است که به دلایل مختلفی از جمله سوءمدیریت، کاهش درآمدها، افزایش بدهی‌ها، نوسانات بازار و شرایط نامساعد اقتصادی رخ می‌دهد. ورشکستگی نه تنها برای شرکت‌ها و مدیران آنها، بلکه برای کل اقتصاد نیز دارای پیامدهای گسترده‌ای است. ورشکستگی می‌تواند موجب از دست رفتن مشاغل، کاهش تولید، افت اعتماد سرمایه‌گذاران و حتی بروز بحران‌های مالی گسترده شود. در بسیاری از موارد، شرکت‌ها به دلیل عدم توانایی در بازپرداخت بدهی‌های خود یا مدیریت ناکارآمد منابع مالی با این مشکل مواجه می‌شوند. از سوی دیگر، شرایط بیرونی مانند رکود اقتصادی یا تغییرات ناگهانی در بازارهای جهانی نیز می‌تواند نقش مهمی در ایجاد بحران‌های مالی برای شرکت‌ها ایفا کند [7-9].

به منظور مدیریت و پیشگیری از ورشکستگی شرکت‌ها، مدل‌های مختلفی برای پیش‌بینی آن توسعه یافته‌اند. یکی از اولین و مهم‌ترین این مدل‌ها، مدل Z آلتمن است که در دهه ۱۹۶۰ معرفی شد. این مدل بر اساس نسبت‌های مالی شرکت‌ها طراحی شده و با استفاده از تحلیل رگرسیونی، احتمال ورشکستگی یک شرکت را پیش‌بینی می‌کند. مدل آلتمن از پنج نسبت مالی استفاده می‌کند که شامل نسبت سرمایه در گردش به دارایی‌ها، سود انباشته به دارایی‌ها، درآمد قبل از بهره و مالیات به دارایی‌ها، ارزش بازار سهام به بدهی‌ها، و فروش به دارایی‌ها می‌شود. این مدل با ترکیب این نسبت‌ها و اعمال وزنی برای هر یک، نمره‌ای به نام Z-Score به شرکت اختصاص می‌دهد که بر اساس آن، احتمال

ورشکستگی شرکت تعیین می‌شود [1]. مدل آلمن به دلیل سادگی و قابلیت اجرا در محیط‌های مختلف، به‌ویژه در صنایع تولیدی، به یکی از مدل‌های پرکاربرد در جهان تبدیل شد.

علاوه بر مدل آلمن، مدل‌های دیگری نیز برای پیش‌بینی ورشکستگی توسعه یافته‌اند. یکی از این مدل‌ها، رگرسیون لجستیک است که با استفاده از داده‌های تاریخی شرکت‌ها و تحلیل نسبت‌های مالی، احتمال ورشکستگی را پیش‌بینی می‌کند. در این مدل، متغیر وابسته به صورت یک متغیر دودویی (ورشکستگی یا عدم ورشکستگی) تعریف می‌شود و با استفاده از تحلیل رگرسیونی، ارتباط میان متغیرهای مستقل (نسبت‌های مالی) و متغیر وابسته مورد بررسی قرار می‌گیرد. رگرسیون لجستیک به دلیل قابلیت استفاده در داده‌های ناهمگون و چندبعدي، یکی از مدل‌های پرکاربرد در پیش‌بینی ورشکستگی است (Jones et al., 2016). همچنین، این مدل امکان به‌کارگیری داده‌های غیرمالی مانند اطلاعات مرتبط با مدیریت، بازار و صنعت را نیز فراهم می‌کند که می‌تواند دقت پیش‌بینی را افزایش دهد.

در سال‌های اخیر، با پیشرفت فناوری و ظهور الگوریتم‌های یادگیری ماشین، مدل‌های پیش‌بینی ورشکستگی با استفاده از این تکنیک‌ها توسعه یافته‌اند. یکی از این مدل‌ها، ماشین بردار پشتیبان است که به دلیل توانایی بالا در دسته‌بندی داده‌های پیچیده و غیرخطی، در پیش‌بینی ورشکستگی مورد توجه قرار گرفته است. این مدل با استفاده از داده‌های مالی و غیرمالی شرکت‌ها، به دنبال یافتن یک مرز بهینه برای تفکیک شرکت‌های ورشکسته و غیرورشکسته است. مزیت اصلی ماشین بردار پشتیبان در مقایسه با مدل‌های سنتی این است که می‌تواند الگوهای پیچیده‌تری را در داده‌ها شناسایی کند و بنابراین دقت پیش‌بینی را افزایش دهد [3].

یکی دیگر از مدل‌های مورد استفاده در پیش‌بینی ورشکستگی، شبکه‌های عصبی مصنوعی است. این مدل‌ها که الهام گرفته از ساختار مغز انسان هستند، قادرند الگوهای پنهان در داده‌های مالی را شناسایی کرده و نتایج پیش‌بینی دقیقی ارائه دهند. شبکه‌های عصبی با استفاده از داده‌های بزرگ و پیچیده، به‌ویژه در شرایطی که الگوهای خطی ساده نمی‌توانند به درستی عمل کنند، عملکرد بسیار خوبی دارند. از این رو، در مطالعات بسیاری نشان داده شده است که شبکه‌های عصبی می‌توانند با دقت بیشتری نسبت به مدل‌های سنتی ورشکستگی شرکت‌ها را پیش‌بینی کنند [4].

تکنیک‌های دیگری نیز همچون الگوریتم‌های تقویتی و درخت تصمیم در پیش‌بینی ورشکستگی استفاده می‌شوند. این الگوریتم‌ها با توجه به ساختار داده‌ها و پیچیدگی آنها، عملکرد خوبی در پیش‌بینی ورشکستگی شرکت‌ها از خود نشان داده‌اند. به‌ویژه الگوریتم‌های تقویتی مانند جنگل تصادفی و بوستینگ که با ترکیب مدل‌های مختلف و بهبود تدریجی عملکرد مدل، توانسته‌اند دقت بالاتری در پیش‌بینی ارائه دهند [7-9].

در کنار این تکنیک‌های پیشرفته، باید به چالش‌ها و محدودیت‌های پیش‌بینی ورشکستگی نیز توجه داشت. یکی از مهم‌ترین این چالش‌ها، مسئله داده‌های نامتوازن است. در بسیاری از موارد، تعداد شرکت‌های ورشکسته نسبت به شرکت‌های غیرورشکسته بسیار کمتر است و این امر می‌تواند باعث کاهش دقت مدل‌های پیش‌بینی شود. تکنیک‌هایی مانند نمونه‌برداری مجدد (Oversampling) و استفاده از الگوریتم‌های حساس به هزینه برای مقابله با این مشکل پیشنهاد شده است [7-9].

در نهایت، با توجه به اهمیت پیش‌بینی ورشکستگی شرکت‌ها و نقش آن در جلوگیری از بحران‌های مالی، توسعه مدل‌های پیشرفته‌تر و دقیق‌تر در این زمینه همچنان یک نیاز اساسی است. مدل‌های یادگیری ماشین به دلیل قابلیت‌های پیشرفته در تحلیل داده‌های پیچیده، در حال حاضر به عنوان یکی از رویکردهای اصلی در پیش‌بینی ورشکستگی مطرح شده‌اند. این مدل‌ها با استفاده از داده‌های مالی و غیرمالی، و با به‌کارگیری تکنیک‌های مختلف مانند شبکه‌های عصبی، ماشین بردار پشتیبان و الگوریتم‌های تقویتی، می‌توانند دقت بالاتری در پیش‌بینی ورشکستگی ارائه دهند. با این حال، نیاز به تحقیق و توسعه بیشتر در زمینه بهبود این مدل‌ها و مقابله با چالش‌های موجود همچنان وجود دارد [5].

استفاده از یادگیری ماشین در پیش‌بینی ورشکستگی به عنوان یکی از پیشرفته‌ترین رویکردهای تحلیلی در دهه‌های اخیر مورد توجه قرار گرفته است. یادگیری ماشین، به واسطه توانایی آن در پردازش حجم عظیمی از داده‌ها و شناسایی الگوهای پیچیده، به یکی از ابزارهای محبوب در پیش‌بینی ورشکستگی شرکت‌ها تبدیل شده است. این تکنیک‌ها به ویژه در شرایطی که مدل‌های سنتی همچون مدل آلمن و رگرسیون لجستیک نتوانسته‌اند به دقت کافی برسند، کارآمدتر ظاهر شده‌اند. الگوریتم‌های یادگیری ماشین، به دلیل توانایی در تحلیل و پردازش داده‌های غیرخطی و چندبعدي، این امکان را فراهم می‌کنند که شرکت‌های ورشکسته و غیرورشکسته را با دقت بیشتری از یکدیگر تفکیک کنند [2]. مطالعات متعددی نشان داده‌اند که الگوریتم‌های یادگیری ماشین، از جمله ماشین بردار پشتیبان (SVM)، شبکه‌های عصبی مصنوعی (ANN)، جنگل‌های تصادفی و الگوریتم‌های بوستینگ، در پیش‌بینی ورشکستگی عملکرد بسیار خوبی دارند. به طور خاص، شبکه‌های عصبی مصنوعی به دلیل توانایی بالای خود در یادگیری الگوهای پنهان و

روابط پیچیده میان داده‌ها، مورد توجه بسیاری از محققان قرار گرفته‌اند. این شبکه‌ها قادرند از طریق لایه‌های مخفی، پیچیدگی‌های موجود در داده‌های مالی را درک کرده و با دقت بالایی ورشکستگی را پیش‌بینی کنند. در یکی از مطالعات، نشان داده شد که شبکه‌های عصبی مصنوعی نسبت به مدل‌های سنتی در پیش‌بینی ورشکستگی عملکرد بهتری دارند و توانسته‌اند با دقت بیشتری شرکت‌های ورشکسته را شناسایی کنند [4].

الگوریتم‌های ماشین بردار پشتیبان نیز یکی دیگر از روش‌های موثر در پیش‌بینی ورشکستگی هستند. این الگوریتم‌ها به دلیل توانایی بالا در دسته‌بندی داده‌های پیچیده و غیرخطی، می‌توانند مرزهای بهینه‌ای برای تفکیک شرکت‌های ورشکسته و غیرورشکسته ایجاد کنند. ماشین بردار پشتیبان با استفاده از داده‌های مالی و حتی داده‌های غیرمالی، مانند اطلاعات مرتبط با مدیریت شرکت، بازار و صنعت، توانسته است دقت بالایی در پیش‌بینی ورشکستگی داشته باشد [3].

یکی از چالش‌های اصلی در استفاده از یادگیری ماشین در پیش‌بینی ورشکستگی، مسئله نامتوازن بودن داده‌ها است. در بسیاری از مجموعه داده‌های مالی، تعداد شرکت‌های ورشکسته نسبت به شرکت‌های غیرورشکسته بسیار کمتر است، که این مسئله می‌تواند باعث کاهش دقت مدل‌ها در پیش‌بینی موارد نادر ورشکستگی شود. برای مقابله با این چالش، تکنیک‌هایی مانند نمونه‌برداری مجدد (Oversampling) یا استفاده از الگوریتم‌های حساس به هزینه پیشنهاد شده است. یکی از این تکنیک‌ها که به تازگی مورد توجه قرار گرفته، تکنیک SMOTE است که با تولید نمونه‌های مصنوعی از داده‌های ورشکسته، توانسته دقت مدل‌های یادگیری ماشین را در پیش‌بینی ورشکستگی افزایش دهد [7-9].

مطالعات دیگر نیز به مقایسه عملکرد الگوریتم‌های مختلف یادگیری ماشین در پیش‌بینی ورشکستگی پرداخته‌اند. به عنوان مثال، در یک مطالعه که به مقایسه الگوریتم‌های ماشین بردار پشتیبان، شبکه‌های عصبی و جنگل‌های تصادفی پرداخته است، نشان داده شد که جنگل‌های تصادفی به دلیل توانایی بالا در تحلیل داده‌های پیچیده و چندبعدی، دقت بیشتری در پیش‌بینی ورشکستگی نسبت به سایر الگوریتم‌ها دارند [6]. همچنین، استفاده از الگوریتم‌های تقویتی مانند XGBoost و Gradient Boosting نیز به عنوان یکی از روش‌های نوآورانه در پیش‌بینی ورشکستگی مطرح شده است. این الگوریتم‌ها با بهبود تدریجی مدل و ترکیب چندین مدل ضعیف‌تر، توانسته‌اند عملکرد مدل‌های پیش‌بینی ورشکستگی را بهبود بخشند [5].

علاوه بر الگوریتم‌های ماشین بردار پشتیبان و شبکه‌های عصبی، تکنیک‌های دیگری نیز در مطالعات پیش‌بینی ورشکستگی مورد بررسی قرار گرفته‌اند. به عنوان مثال، الگوریتم‌های درخت تصمیم و الگوریتم‌های تقویتی مانند AdaBoost و Random Forest نیز توانسته‌اند در برخی موارد دقت بالایی در پیش‌بینی ورشکستگی شرکت‌ها ارائه دهند. این الگوریتم‌ها با ساخت چندین درخت تصمیم و ترکیب نتایج آنها، به دنبال ایجاد یک مدل پیش‌بینی دقیق‌تر هستند. به ویژه درخت‌های تصمیم که ساختاری ساده و قابل فهم دارند، به مدیران و تحلیل‌گران این امکان را می‌دهند تا به راحتی نتایج مدل‌های پیش‌بینی ورشکستگی را تفسیر کنند [7-9].

یکی دیگر از مباحث مطرح در مطالعات پیش‌بینی ورشکستگی با استفاده از یادگیری ماشین، استفاده از داده‌های ترکیبی مالی و غیرمالی است. در برخی از مطالعات نشان داده شده است که ترکیب داده‌های مالی و غیرمالی می‌تواند دقت مدل‌های یادگیری ماشین را به طور قابل توجهی افزایش دهد. برای مثال، داده‌های مربوط به مدیریت شرکت، وضعیت بازار و حتی شاخص‌های کلان اقتصادی می‌توانند به عنوان عواملی تاثیرگذار در پیش‌بینی ورشکستگی مورد استفاده قرار گیرند. این داده‌ها می‌توانند اطلاعات ارزشمندی را درباره وضعیت کلی شرکت و صنعت ارائه دهند که در تحلیل نهایی مدل‌های یادگیری ماشین تاثیرگذار خواهند بود [10].

در نهایت، مطالعات نشان می‌دهند که با توجه به پیچیدگی‌های موجود در پیش‌بینی ورشکستگی و نیاز به تحلیل دقیق داده‌های مالی و غیرمالی، استفاده از الگوریتم‌های یادگیری ماشین می‌تواند ابزار قدرتمندی برای مدیریت ریسک‌های مالی و جلوگیری از وقوع ورشکستگی باشد. همچنین، با توجه به پیشرفت‌های سریع در حوزه فناوری و یادگیری ماشین، بهبود مداوم مدل‌ها و روش‌های پیش‌بینی ورشکستگی همچنان به عنوان یک نیاز اساسی در مطالعات مالی باقی مانده است [5].

بحث و بررسی

مدل‌های مختلف یادگیری ماشین برای پیش‌بینی ورشکستگی به عنوان ابزاری کارآمد در مواجهه با پیچیدگی‌های مالی و تجاری به کار رفته‌اند. این مدل‌ها، با توانایی شناسایی الگوهای پنهان در داده‌های پیچیده و چندبعدی، عملکرد بسیار بهتری نسبت به روش‌های سنتی نشان داده‌اند. یکی از این مدل‌ها، درخت تصمیم است. این مدل بر اساس تقسیم

داده‌ها به شاخه‌های مختلف و ایجاد یک ساختار سلسله‌مراتبی عمل می‌کند. درخت تصمیم به دلیل سادگی و قابلیت تفسیر بالای نتایج، یکی از مدل‌های محبوب در پیش‌بینی ورشکستگی است. این مدل می‌تواند با استفاده از مجموعه‌ای از قواعد تصمیم‌گیری، داده‌ها را به دسته‌های مختلف تقسیم کند و در نهایت به پیش‌بینی ورشکستگی یا عدم ورشکستگی شرکت‌ها بپردازد. مطالعات نشان داده‌اند که درخت تصمیم در شرایطی که داده‌های مالی به سادگی قابل طبقه‌بندی هستند، عملکرد خوبی از خود نشان می‌دهد [7-9]. با این حال، یکی از محدودیت‌های این مدل عدم توانایی آن در مواجهه با داده‌های بسیار پیچیده و غیرخطی است.

یکی دیگر از مدل‌های مورد استفاده در پیش‌بینی ورشکستگی، جنگل تصادفی است. این مدل به عنوان یک توسعه یافته از درخت تصمیم، با ترکیب چندین درخت تصمیم به صورت تصادفی، عملکرد بهتری در پیش‌بینی ورشکستگی نشان داده است. جنگل تصادفی با انتخاب تصادفی ویژگی‌ها و داده‌ها برای هر درخت، به کاهش تعصب و افزایش دقت پیش‌بینی کمک می‌کند. یکی از مزایای اصلی جنگل تصادفی، توانایی آن در مواجهه با داده‌های پیچیده و نامتوازن است. مطالعات تجربی نشان داده‌اند که این مدل در پیش‌بینی ورشکستگی شرکت‌ها، به ویژه در صنایع مختلف، عملکرد بهتری نسبت به سایر مدل‌ها دارد [3]. همچنین جنگل تصادفی می‌تواند داده‌های مالی و غیرمالی را به صورت همزمان پردازش کرده و نتایج دقیقی ارائه دهد.

شبکه‌های عصبی مصنوعی یکی دیگر از مدل‌های پرکاربرد در پیش‌بینی ورشکستگی است. این مدل با الهام از ساختار مغز انسان، قادر است الگوهای پیچیده و غیرخطی را در داده‌ها شناسایی کند. شبکه‌های عصبی با استفاده از لایه‌های مخفی و وزن‌دهی به ارتباطات میان نورون‌ها، می‌توانند داده‌های پیچیده را پردازش کرده و نتایج دقیقی از پیش‌بینی‌ها ارائه دهند. مطالعات نشان داده‌اند که شبکه‌های عصبی مصنوعی به ویژه در شرایطی که داده‌های مالی به شدت پیچیده هستند و الگوهای خطی به درستی عمل نمی‌کنند، عملکرد بسیار بهتری نسبت به مدل‌های سنتی دارند [4]. یکی از مزایای اصلی شبکه‌های عصبی، توانایی آن‌ها در یادگیری از داده‌های بزرگ و پیچیده است. این مدل‌ها می‌توانند از داده‌های تاریخی برای بهبود عملکرد پیش‌بینی‌های خود استفاده کنند و با هر بار آموزش، دقت خود را افزایش دهند.

مدل ماشین بردار پشتیبان (SVM) یکی دیگر از مدل‌های قدرتمند در پیش‌بینی ورشکستگی است. این مدل با استفاده از مفهوم «مرز تصمیم» یا «هایپرپلن» به تفکیک داده‌های ورشکسته و غیرورشکسته می‌پردازد. ماشین بردار پشتیبان با یافتن بهترین مرز میان داده‌های دو دسته، به پیش‌بینی دقیق‌تر کمک می‌کند. یکی از ویژگی‌های برجسته این مدل، توانایی آن در پردازش داده‌های غیرخطی و پیچیده است. ماشین بردار پشتیبان با استفاده از تکنیک‌های کرنل، می‌تواند داده‌های غیرخطی را به فضای بالاتری منتقل کرده و به پیش‌بینی دقیق‌تری دست یابد [5]. مطالعات تجربی نشان داده‌اند که ماشین بردار پشتیبان در بسیاری از موارد نسبت به سایر مدل‌ها دقت بیشتری در پیش‌بینی ورشکستگی ارائه داده است.

در مقایسه عملکرد مدل‌های مختلف یادگیری ماشین، داده‌های تجربی از مطالعات پیشین نشان داده‌اند که مدل‌های مبتنی بر الگوریتم‌های تقویتی مانند XGBoost و Gradient Boosting نیز عملکرد بسیار خوبی در پیش‌بینی ورشکستگی داشته‌اند. این الگوریتم‌ها با تقویت تدریجی مدل‌های ضعیف‌تر و ترکیب آن‌ها به یک مدل قوی‌تر، توانسته‌اند دقت بالاتری در پیش‌بینی‌ها ارائه دهند. مطالعات نشان داده‌اند که این مدل‌ها به ویژه در شرایطی که داده‌های مالی نامتوازن و پیچیده هستند، عملکرد بهتری نسبت به مدل‌های سنتی مانند رگرسیون لجستیک داشته‌اند [6]. به عنوان مثال، الگوریتم XGBoost با کاهش خطای مدل و بهبود تدریجی عملکرد، توانسته است به یکی از پرکاربردترین مدل‌ها در پیش‌بینی ورشکستگی تبدیل شود.

یکی از چالش‌های اساسی در تحلیل عملکرد مدل‌های مختلف، مسئله تعادل میان دقت و قابلیت تفسیر نتایج است. برخی از مدل‌ها مانند درخت تصمیم و جنگل تصادفی، به دلیل سادگی و قابلیت تفسیر بالا، برای مدیران و تحلیل‌گران مالی جذاب‌تر هستند. این مدل‌ها به راحتی قابل تفسیر و اجرا در محیط‌های مختلف هستند و می‌توانند به سرعت نتایج پیش‌بینی را ارائه دهند. با این حال، مدل‌هایی مانند شبکه‌های عصبی و ماشین بردار پشتیبان به دلیل پیچیدگی بالای خود، نیاز به پردازش و تحلیل بیشتری دارند و در بسیاری از موارد نتایج آن‌ها به سادگی قابل تفسیر نیستند [7-9]. این مسئله می‌تواند به عنوان یک چالش در استفاده از این مدل‌ها مطرح شود، زیرا مدیران ممکن است به نتایج مدل‌های پیچیده‌تر اعتماد نکنند.

در نهایت، مقایسه عملکرد مدل‌های یادگیری ماشین بر اساس داده‌های تجربی نشان می‌دهد که هیچ مدل واحدی برای تمامی شرایط و صنایع مناسب نیست. به عبارت دیگر، انتخاب مدل مناسب برای پیش‌بینی ورشکستگی به عواملی همچون نوع داده‌ها، پیچیدگی مسئله، و نیاز به دقت یا قابلیت تفسیر بستگی دارد. به عنوان مثال، در صنایعی که

داده‌های مالی ساده و قابل تفسیر هستند، مدل‌های ساده‌تری مانند درخت تصمیم و رگرسیون لجستیک ممکن است عملکرد بهتری داشته باشند. اما در صنایعی که داده‌های پیچیده‌تر و چندبعدی وجود دارد، مدل‌های پیشرفته‌تری مانند شبکه‌های عصبی و ماشین بردار پشتیبان ممکن است دقت بیشتری ارائه دهند [10].

بحث و نتیجه‌گیری

استفاده از مدل‌های یادگیری ماشین در پیش‌بینی ورشکستگی شرکت‌ها با وجود دقت بالا و توانایی شناسایی الگوهای پیچیده در داده‌ها، با چالش‌ها و محدودیت‌هایی همراه است. این چالش‌ها نه تنها مرتبط با ساختار و پیچیدگی الگوریتم‌هاست، بلکه به کیفیت و نوع داده‌های ورودی نیز بستگی دارد. یکی از اصلی‌ترین چالش‌های موجود در این زمینه، کیفیت داده‌هایی است که برای آموزش و ارزیابی مدل‌های یادگیری ماشین استفاده می‌شود. داده‌های مالی و غیرمالی مورد استفاده برای پیش‌بینی ورشکستگی باید دقیق، کامل و به‌روز باشند. هر گونه نقص در داده‌ها، مانند وجود داده‌های ناقص یا نادرست، می‌تواند باعث کاهش دقت مدل‌های یادگیری ماشین شود. بسیاری از مطالعات نشان داده‌اند که دقت پیش‌بینی مدل‌ها به شدت به کیفیت داده‌های ورودی وابسته است، به طوری که استفاده از داده‌های ناقص یا قدیمی می‌تواند به نتایج اشتباه و گمراه‌کننده منجر شود [3].

یکی دیگر از چالش‌های مهم در استفاده از یادگیری ماشین برای پیش‌بینی ورشکستگی، مسئله عدم توازن داده‌هاست. در بسیاری از موارد، تعداد شرکت‌های ورشکسته نسبت به شرکت‌های غیرورشکسته بسیار کمتر است، که این مسئله می‌تواند باعث عدم دقت مدل‌ها در پیش‌بینی موارد نادر ورشکستگی شود. مدل‌های یادگیری ماشین معمولاً در مواجهه با داده‌های نامتوازن، تمایل به طبقه‌بندی اکثریت داده‌ها به دسته غالب (شرکت‌های غیرورشکسته) دارند و در نتیجه، پیش‌بینی‌های نادرست در مورد شرکت‌های ورشکسته افزایش می‌یابد. برای مقابله با این مشکل، تکنیک‌های مختلفی همچون نمونه‌برداری مجدد (Oversampling) و تکنیک‌های حساس به هزینه پیشنهاد شده است. این تکنیک‌ها با افزایش تعداد نمونه‌های ورشکسته یا تنظیم وزن‌های مدل برای اهمیت دادن به داده‌های نادر، می‌توانند دقت مدل‌ها را بهبود بخشند [7-9].

از دیگر چالش‌های مهم در استفاده از یادگیری ماشین، پیچیدگی بالای الگوریتم‌ها و نیاز به تنظیمات دقیق مدل‌هاست. بسیاری از الگوریتم‌های پیشرفته مانند شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان دارای تنظیمات پیچیده‌ای هستند که شامل تعداد لایه‌ها، تعداد نورون‌ها، و تنظیم پارامترهای مختلف است. انتخاب پارامترهای مناسب و تنظیم دقیق این الگوریتم‌ها نیاز به تجربه و دانش فنی بالا دارد و عدم تنظیم مناسب می‌تواند باعث کاهش عملکرد مدل شود. علاوه بر این، برخی از این الگوریتم‌ها مانند شبکه‌های عصبی مصنوعی به حجم زیادی از داده‌ها برای آموزش نیاز دارند و در صورتی که داده‌های کافی برای آموزش مدل در دسترس نباشد، دقت پیش‌بینی به شدت کاهش می‌یابد [4]. یکی دیگر از مشکلات مرتبط با استفاده از الگوریتم‌های یادگیری ماشین در پیش‌بینی ورشکستگی، عدم شفافیت و تفسیرپذیری نتایج است. بسیاری از مدل‌های پیشرفته یادگیری ماشین مانند شبکه‌های عصبی و الگوریتم‌های تقویتی به دلیل ساختار پیچیده و چندلایه‌ای خود، نتایجی تولید می‌کنند که برای تحلیل‌گران و مدیران مالی به سختی قابل تفسیر هستند. این مسئله به‌ویژه در محیط‌های کسب‌وکار که تصمیمات مالی باید به سرعت و با اطمینان اتخاذ شوند، می‌تواند به عنوان یک چالش جدی مطرح شود. مدل‌های پیچیده معمولاً نتایج دقیق‌تری ارائه می‌دهند، اما در عین حال تفسیر نتایج و دلایل پیش‌بینی‌های انجام‌شده به سختی قابل توضیح است. به همین دلیل، بسیاری از شرکت‌ها و مدیران تمایل به استفاده از مدل‌های ساده‌تر و قابل تفسیرتر مانند درخت تصمیم یا رگرسیون لجستیک دارند [6].

یکی از چالش‌های دیگری که در استفاده از یادگیری ماشین برای پیش‌بینی ورشکستگی وجود دارد، تأثیر عوامل خارجی و شرایط محیطی بر عملکرد مدل‌هاست. بازارهای مالی و اقتصادی به شدت پویا و متغیر هستند و تغییرات ناگهانی در شرایط اقتصادی می‌تواند باعث نوسانات شدید در داده‌های مالی شرکت‌ها شود. مدل‌های یادگیری ماشین که بر اساس داده‌های گذشته آموزش دیده‌اند، ممکن است در مواجهه با تغییرات ناگهانی بازار عملکرد مناسبی نداشته باشند. به عنوان مثال، در دوران رکود اقتصادی یا بحران‌های مالی جهانی، بسیاری از شرکت‌ها ممکن است به دلایل خارجی ورشکسته شوند و مدل‌های یادگیری ماشین قادر به پیش‌بینی صحیح این شرایط نباشند [5].

در نهایت، یکی دیگر از محدودیت‌های مهم استفاده از یادگیری ماشین در پیش‌بینی ورشکستگی، نیاز به داده‌های گسترده و با کیفیت بالا برای آموزش مدل‌هاست. بسیاری از مدل‌های پیشرفته مانند شبکه‌های عصبی و الگوریتم‌های تقویتی به حجم زیادی از داده‌های مالی و غیرمالی نیاز دارند تا بتوانند الگوهای پنهان را شناسایی کنند و پیش‌بینی‌های دقیقی ارائه دهند. با این حال، در بسیاری از موارد، داده‌های کافی و با کیفیت برای آموزش این مدل‌ها در دسترس نیست و این مسئله می‌تواند عملکرد مدل‌ها را به شدت تحت تأثیر قرار دهد. علاوه بر این، جمع‌آوری و پردازش داده‌های بزرگ نیازمند منابع مالی و زمانی قابل توجهی است و بسیاری از شرکت‌ها قادر به تأمین این منابع نیستند [7-9].

با توجه به چالش‌ها و محدودیت‌های ذکر شده، استفاده از یادگیری ماشین برای پیش‌بینی ورشکستگی همچنان به عنوان یکی از ابزارهای قدرتمند در مدیریت ریسک‌های مالی محسوب می‌شود، اما نیازمند بهبود و توسعه مداوم است. مدل‌های یادگیری ماشین با وجود چالش‌های موجود، همچنان می‌توانند به شرکت‌ها و نهادهای مالی در پیش‌بینی ورشکستگی کمک کرده و آن‌ها را از وقوع بحران‌های مالی محافظت کنند. با این حال، تحقیقات بیشتری برای بهبود کیفیت داده‌ها، مقابله با نامتوازنی داده‌ها و افزایش شفافیت مدل‌ها لازم است تا دقت و کارایی این مدل‌ها بهبود یابد [10].

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تشکر و قدردانی

از تمامی کسانی که در طی مراحل این پژوهش به ما یاری رساندند تشکر و قدردانی می‌گردد.

تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

حمایت مالی

این پژوهش حامی مالی نداشته است.

موازن اخلاقی

در انجام این پژوهش تمامی موازن و اصول اخلاقی رعایت گردیده است.

References

- [1] E. I. Altman, M. Iwanicz-Drozowska, E. K. Laitinen, and A. Suvas, "Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's *Z*-Score Model," *Journal of International Financial Management and Accounting*, vol. 28, no. 2, pp. 131-171, 2016, doi: 10.1111/jifm.12053.
- [2] T. M. Alam *et al.*, "Corporate Bankruptcy Prediction: An Approach Towards Better Corporate World," *The Computer Journal*, vol. 64, no. 11, pp. 1731-1746, 2020, doi: 10.1093/comjnl/bxaa056.
- [3] J. Horák, J. Vrbka, and P. Šuleř, "Support Vector Machine Methods and Artificial Neural Networks Used for the Development of Bankruptcy Prediction Models and Their Comparison," *Journal of Risk and Financial Management*, vol. 13, no. 3, p. 60, 2020, doi: 10.3390/jrfm13030060.
- [4] X. Brédart, "A "User Friendly" Bankruptcy Prediction Model Using Neural Networks," *Accounting and Finance Research*, vol. 3, no. 2, 2014, doi: 10.5430/afr.v3n2p124.
- [5] U. Mukherjee, V. Thakkar, S. Dutta, U. Mukherjee, and S. K. Bandyopadhyay, "Emerging Approach for Detection of Financial Frauds Using Machine Learning," *Asian Journal of Research in Computer Science*, pp. 9-22, 2021, doi: 10.9734/ajrcos/2021/v11i330263.
- [6] C. F. Tsai, "Two-stage Hybrid Learning Techniques for Bankruptcy Prediction*," *Statistical Analysis and Data Mining the Asa Data Science Journal*, vol. 13, no. 6, pp. 565-572, 2020, doi: 10.1002/sam.11482.
- [7] T. Le, M. Y. Lee, J. R. Park, and S. W. Baik, "Oversampling Techniques for Bankruptcy Prediction: Novel Features From a Transaction Dataset," *Symmetry*, vol. 10, no. 4, p. 79, 2018, doi: 10.3390/sym10040079.
- [8] T. Le, L. H. Son, M. T. Vo, M. Y. Lee, and S. W. Baik, "A Cluster-Based Boosting Algorithm for Bankruptcy Prediction in a Highly Imbalanced Dataset," *Symmetry*, vol. 10, no. 7, p. 250, 2018, doi: 10.3390/sym10070250.
- [9] T. Le, M. T. Vo, B. Vo, M. Y. Lee, and S. W. Baik, "A Hybrid Approach Using Oversampling Technique and Cost-Sensitive Learning for Bankruptcy Prediction," *Complexity*, vol. 2019, no. 1, 2019, doi: 10.1155/2019/8460934.

- [10] G. Lombardo, M. Pellegrino, G. Adosoglou, S. Cagnoni, P. M. Pardalos, and A. Poggi, "Machine Learning for Bankruptcy Prediction in the American Stock Market: Dataset and Benchmarks," *Future Internet*, vol. 14, no. 8, p. 244, 2022, doi: 10.3390/fi14080244.
- [11] S. Devi and Y. Radhika, "A Survey on Machine Learning and Statistical Techniques in Bankruptcy Prediction," *International Journal of Machine Learning and Computing*, vol. 8, no. 2, pp. 133-139, 2018, doi: 10.18178/ijmlc.2018.8.2.676.