

Systematic review of bankruptcy prediction models

Jaber Zahmatkesh¹, Akram Taftiyan², Mahmoud Moeinadin¹, Amin Nezarat³

Received: 04/07/2023

Accepted: 24/10/2023

Extended Abstract

Introduction

Bankruptcy is one of the important elements of the structure of the market system and its purpose is to protect socio-economic processes against the results of inefficient activities of members and non-fulfillment of obligations. As a result of bankruptcy, bankrupt companies are removed from the market economy, that is, resources are distributed from inefficient owners to those who do the most efficient work, which means that bankruptcy is one of the ways to improve the country's economy. Bankruptcy prediction models designed to be as accurate as possible, but not sufficiently acceptable and interpretable from an economic point of view, are unlikely to be useful in practice. Unlike linear regression techniques, new bankruptcy prediction models, such as neural networks and gradient boosting models that consider nonlinear relationships, do not clearly show how explanatory variables and bankruptcy probability are related. This often happens when there are non-linear relationships between the explanatory variables and the predictive or non-uniform effects of the explanatory variables on the probability of bankruptcy. An effective bankruptcy prediction model should show the true effects of the most important explanatory variables on the probability of bankruptcy and still be clear and interpretable. Moreover, the main criterion for evaluating such a model should be how it affects the profitability of decision-making, rather than validity criteria based solely on probability or classification.

Literature Review


Bankruptcy prediction models are valuable analytical tools used by entrepreneurs, financial institutions and individual investors alike. However, despite the use of sophisticated methods, their effectiveness still needs to be improved. There may be many reasons why bankruptcy models are unreliable. Some bankruptcies

1. Department of Accounting, Yazd Branch, Islamic Azad University, Yazd, Iran.

2. Department of Accounting, Yazd Branch, Islamic Azad University, Yazd, Iran. (Corresponding Author).
Taftiyan@iauyazd.ac.ir

3. Department of Computer Engineering, Yazd Branch, Islamic Azad University, Yazd, Iran.

How to cite this paper: Zahmatkesh, J., Taftiyan, A., Moeinadin, M., & Nezarat, A. (2023). Systematic review of bankruptcy prediction models. *Advances in Finance and Investment*, 4(4), 117-144. [In Persian]

 <https://doi.org/10.30495/afi.2023.1971181.1164>

cannot be predicted because they are caused by sudden, unusual and unexpected events. In some cases, the problem may be due to poor bankruptcy forecasting methods. It is also possible that errors in bankruptcy prediction are related to the poor quality of data published in financial statements. Unreliable data can be resulted from unintentional mistakes by accountants and deliberate manipulation of financial statements. The trend of studies shows that although statistical models can provide good predictions for corporate bankruptcy, the limiting assumptions of some of these models, such as linearity, normality and independence of predictor variables, have affected their effectiveness; Therefore, to overcome these limitations and improve the performance of predictions, artificial intelligence techniques were gradually developed. Bankruptcy artificial intelligence models mainly focus on signs of business incapacity. They are generally multivariate and the variables used in them are extracted from the data of the company's financial statements.

Research Methodology

The present study is a systematic review. To collect the required articles, help can be got from Google Scholar, Wiley Interscience, Science Direct, Web of Science and Business Source Complete databases. In this research, the required data was extracted using Web of Science. For the initial search in the mentioned database, keywords such as Bankruptcy, Default, Distress, Failure, Forecasting, Insolvency, Predicting, Prediction and also from the operators AND, OR and NOT was used in the Title field so that the search engine could find all the available articles as much as possible. Among the possible states, the only keyword that found a significant number of articles is Bankruptcy. The results of the initial search were 1000 articles which were screened in this database to find documents related to the research topic using built-in limiting filters (filters such as document type, article publication language, publication year and Web of Science domains). By applying the first filter in the document type section (selecting Article), 400 articles were removed and by selecting the English language, 51 articles were removed. Also, by applying the time limit of 2015 to 2023, 234 articles were selected and 266 articles were removed due to lack of subject relevance and 49 final articles related to the purpose of the study were identified and selected. Considering that the Web of Science scientific database is constantly being updated, therefore, if a researcher does this search at another time, he will probably reach independent results that are not consistent with the current results.

Results

According to the findings of the current research, artificial neural network and support vector machines are the most suitable tools and they fulfill some criteria of bankruptcy prediction models.

Discussion and Conclusion

The result of the present study is that the developers of bankruptcy prediction models, instead of choosing based on popularity or other non-scientific factors, can now make informed decisions regarding the selection of tools for their model. Essentially, tools are often chosen based on their strengths. Another consequence is that bankruptcy prediction models with better performance will generally be more developed according to the needs of end users. The framework of the present study reduces the waste of time in the process of developing many bankruptcy prediction models with different tools in order to choose the best option after a series of tests; Only tools that best fit the developer's situation will be used and compared.

Future studies should consider the possibilities of interpreting the results of artificial neural network and support vector machines because they are the most appropriate tools and fulfill some of the criteria of bankruptcy prediction models. The best overall model that performs better than other models according to all or most of the criteria, although it has not yet been determined, may be in the form of a combination of tools; Therefore, future research should, on the one hand, investigate different combinations in order to develop the best combination that can achieve this adaptation. On the other hand, future studies should consider using more sophisticated tools such as Barrett machines, highly random trees, etc. Since the tools that can be used with qualitative variables were presented in this study, future studies should consider the inclusion of qualitative variables in the development of bankruptcy prediction models as suggested in many studies. Meanwhile, future studies should combine quantitative and qualitative variables using these tools from the point of view of developing bankruptcy prediction models with better performance.

Conflict of Interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

Keywords: Artificial intelligence tools, Bankruptcy prediction models, Statistical tools, Systematic review.

JEL Classification: C38, D11, E64, M40.

پیشرفت‌های مالی و سرمایه‌گذاری

سال چهارم، زمستان ۱۴۰۲ - شماره ۴

صفحات ۱۱۷-۱۴۴

نوع مقاله: پژوهشی

بررسی نظام‌مند مدل‌های پیش‌بینی ورشکستگی

جابر زحمتکش^۱، اکرم تفتیان^۲، محمود معین‌الدین^۱، امین نظارات^۳

تاریخ پذیرش: ۱۴۰۲/۰۸/۰۲

تاریخ دریافت: ۱۴۰۲/۰۴/۱۳

چکیده

هدف: هدف پژوهش حاضر بررسی نظام‌مند مدل‌های پیش‌بینی ورشکستگی در راستای ایجاد مدلی است که به‌عنوان راهنمایی برای انتخاب ابزار مناسب که بهترین انطباق را با داده‌های موجود و معیارهای کیفیت مدل‌های پیش‌بینی ورشکستگی دارد عمل کند.

روش‌شناسی پژوهش: برای انجام این پژوهش، جستجوی سیستماتیک از database (web of Science) با استفاده از کلیدواژه‌های Bankruptcy, Default, Distress, Failure, Forecasting, Predicting, Prediction و Insolvency بین سال‌های ۲۰۱۵ لغایت ۲۰۲۳ صورت پذیرفت. با توجه به معیارهای ورود و خروج تعریف‌شده، حاصل این جستجو ۱۰۰۰ مقاله بود که در نهایت ۴۹ مقاله از میان آن‌ها انتخاب و مورد تجزیه و تحلیل قرار گرفت. سپس یافته‌های به‌دست‌آمده از مقالات، در جداول خلاصه‌سازی وارد گردیده و در گام بعدی، مدل‌های بزرگ پیش‌بینی ورشکستگی بر اساس ۹ معیار کلیدی با یکدیگر مقایسه و نتیجه‌گیری نهایی به عمل آمد.

یافته‌ها: شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان دارای بیشترین دقت می‌باشند در حالی که تحلیل شخصیتی چندگانه دارای کمترین دقت است. همچنین شبکه عصبی مصنوعی و تحلیل شخصیتی چندگانه، درخت تصمیم‌گیری و رگرسیون لجستیک به نمونه آموزشی بزرگی نیاز دارند تا الگویی را منطقی‌شناسایی کرده و طبقه‌بندی بسیار دقیقی ارائه دهند؛ اما استدلال مبتنی بر مورد، مجموعه‌های راف و ماشین‌های بردار پشتیبان می‌توانند با اندازه نمونه‌های کوچک کار کنند.

اصالت / ارزش‌افزوده علمی: نتایج این پژوهش به درک کامل ویژگی‌های ابزارهای مورد استفاده برای توسعه مدل‌های پیش‌بینی ورشکستگی و کاستی‌های مربوط به آن‌ها کمک می‌کند.

کلیدواژه‌ها: ابزارهای آماری، ابزارهای هوش مصنوعی، بررسی نظام‌مند، مدل‌های پیش‌بینی ورشکستگی.

طبقه‌بندی موضوعی: M40, E64, D11, C38.

۱. گروه حسابداری، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران.

۲. گروه حسابداری، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران. (نویسنده مسئول). Taftiyan@iauyazd.ac.ir

۳. گروه مهندسی کامپیوتر، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران.

استناد: زحمتکش، جابر؛ تفتیان، اکرم؛ معین‌الدین، محمود؛ نظارات، امین. (۱۴۰۲). بررسی نظام‌مند مدل‌های پیش‌بینی ورشکستگی. پیشرفت‌های مالی و سرمایه‌گذاری، ۴(۴)، ۱۱۷-۱۴۴.

۱- مقدمه

ورشکستگی یکی از عناصر مهم ساختار نظام بازار است و هدف آن حفاظت از فرآیندهای اجتماعی - اقتصادی در برابر نتایج فعالیت‌های ناکارآمد اعضا و عدم انجام تعهدات است. در نتیجه ورشکستگی، شرکت‌های ورشکسته از اقتصاد بازار حذف می‌شوند، یعنی منابع از صاحبان ناکارآمد به کسانی که کارآمدترین کار را انجام می‌دهند، توزیع می‌شود؛ به این معنی که ورشکستگی یکی از راه‌های بهبود اقتصاد کشور است (Mućko and Adamczyk, 2023). تعیین دلایل اصلی ورشکستگی، اهمیت زیادی دارد. در اغلب موارد دلایلی متعددی به پدیده ورشکستگی منجر می‌شوند؛ بنابراین تعیین دقیق آن‌ها به‌آسانی امکان‌پذیر نیست. با وجود این، می‌توان این عوامل را در دو گروه کلی دلایل درون‌سازمانی و برون‌سازمانی، طبقه‌بندی کرد. یکی از دلایل شکست تجاری از واکنش نشان‌دادن مدیران در موقعیت‌های خاص و نه واکنش نامناسب آن‌ها نشئت می‌گیرد (Ghamari Moghaddam et al., 2022). مدل‌های پیش‌بینی ورشکستگی تا حد امکان دقیق طراحی شده‌اند؛ اما از دیدگاه اقتصادی به اندازه کافی قابل قبول و قابل تفسیر نیستند؛ بعید است در عمل مفید باشند. برخلاف تکنیک‌های رگرسیون خطی، مدل‌های جدید پیش‌بینی ورشکستگی، مانند شبکه‌های عصبی و مدل‌های تقویت گرادیان که روابط غیرخطی را در نظر می‌گیرند، به‌وضوح نشان نمی‌دهند که متغیرهای توضیحی و احتمال ورشکستگی چگونه به هم مرتبط هستند. این اغلب زمانی اتفاق می‌افتد که روابط غیرخطی بین متغیرهای توضیحی و اثرات پیش‌بینی‌کننده یا غیریک‌نواخت متغیرهای توضیحی بر احتمال ورشکستگی وجود دارد. یک مدل پیش‌بینی ورشکستگی مؤثر باید تأثیرات واقعی مهم‌ترین متغیرهای توضیحی را بر روی احتمال ورشکستگی نشان دهد و همچنان واضح و قابل تفسیر باشد. علاوه بر این، معیار اصلی برای ارزیابی چنین مدلی باید چگونگی تأثیر آن بر سودآوری تصمیم‌گیری باشد نه معیارهای اعتباری که صرفاً بر اساس احتمال یا طبقه‌بندی است (Lohmann et al., 2022). یکی از مشکلاتی که بسیاری از مدل‌ها برای پیش‌بینی سهم ورشکستگی دارند این است که نه معیارهای اعتبار مبتنی بر احتمال و نه آن‌هایی که مبتنی بر طبقه‌بندی هستند، سودآوری اقتصادی مرتبط را که با یک مدل پیش‌بینی ورشکستگی کم‌وبیش دقیق مرتبط است، در نظر نمی‌گیرند. اگر احتمال ورشکستگی تخمین زده شده بر سودآوری تأثیر بگذارد، این معیارهای اعتبار رایج ممکن است به نتایج نادرستی در مورد پیامدهای اقتصادی یک مدل تجربی خاص منجر شود. به طور خاص، هزینه‌های ناشی از طبقه‌بندی نادرست شرکت‌هایی که در واقع ورشکسته هستند و سود ازدست‌رفته ناشی از طبقه‌بندی اشتباه شرکت‌هایی که در واقع حلال هستند، باید در نظر گرفته شوند. در نتیجه، از نظر اقتصادی، یک مدل تجربی که از نظر آماری معتبرتر است ممکن است نسبت به جایگزینی با اعتبار آماری پایین‌تر مطلوبیت

کمتری داشته باشد. به طور کلی، معیارهای اعتبار سنتی به دلیل اینکه سودآوری مدل‌های پیش‌بینی ورشکستگی را در نظر نمی‌گیرند، ناسازگار عمل می‌کنند (Vlaović-Begović et al., 2022). پژوهش‌های در زمینه پیش‌بینی ورشکستگی به دهه ۱۹۳۰ برمی‌گردد و از آن زمان تاکنون مطالعات متعددی انجام شده است که به‌سادگی می‌توان آن‌ها را با توجه به روش مورد استفاده (رویکرد آماری، یادگیری ماشینی و یادگیری عمیق) و نوع داده (کمی، کیفی، مالی و غیرمالی) مورد استفاده برای ساخت مدل پیش‌بینی متمایز کرد. مطالعات کلاسیک در پیش‌بینی ورشکستگی عمدتاً از رویکرد آماری استفاده کرده‌اند. ستون‌های موجود در این زمینه شامل بیور (Beaver, 1966) است که اولین کسی بود که سودمندی نسبت‌های مالی را در پیش‌بینی ورشکستگی تعیین کرد. بی‌توجهی به موضوع پژوهش حاضر موجب می‌گردد تا سرمایه‌گذاران از آگاهی کافی در خصوص شیوه پیش‌بینی خطر ورشکستگی شرکت‌های فعال در بازار سرمایه ایران برخوردار نباشند و به دلیل عدم آگاهی در این زمینه، در تصمیمات اقتصادی خود دچار اشتباه شده و از این بابت متضرر شوند؛ بنابراین به‌منظور پیشگیری از این مشکل احتمالی ضرورت دارد تا مدل‌های قابل‌استفاده در ارتباط با پیش‌بینی ورشکستگی شرکت‌های فعال در بازار سهام ایران به تفکیک صنایع پرقابیت مورد مقایسه قرار گیرند و در نهایت مدل بهینه در این زمینه انتخاب شود. پژوهش‌های قبلی انجام شده در حوزه ورشکستگی (Haghparast et al., 2021 and Heidary et al., 2021) اغلب مدل‌های پیش‌بینی ورشکستگی ارائه شده توسط پژوهشگران خارجی را در محیط اقتصادی ایران مورد باز آزمون قرار داده‌اند و به مقایسه این مدل‌ها پرداخته‌اند. با توجه به اشکالات شرکت‌ها در ایران در حیطه‌های پیش‌بینی ورشکستگی و به دلیل نیاز مبرم ذی‌نفعان شرکت‌ها از میزان ورشکستگی، هدف پژوهش حاضر جستجوی سیستماتیک مزایا و معایب مدل‌های پیش‌بینی ورشکستگی برای انتخاب مدل (مدل‌های) مرجع جهت الگوبرداری برای طراحی یک مدل پیش‌بینی ورشکستگی با استفاده از روش‌های علمی و معتبر می‌باشد. با این حال، در ایران پژوهشی که به مرور سیستماتیک مدل‌های پیش‌بینی ورشکستگی پرداخته باشد، انجام نشده است که در این حوزه فقدان مطالعاتی احساس می‌شود. در ادامه، ابتدا، مبانی نظری پژوهش بیان و پیشینه مرتبط با آن مرور شده است. سپس، روش مورد استفاده تشریح شده است. در بخش بعد، نتایج برآوردی مورد بحث و بررسی قرار گرفته و در پایان برابر نتیجه‌گیری به‌عمل آمده، پیشنهادها ارائه شده است.

۲- مبانی نظری و پیشینه پژوهش

مدل‌های پیش‌بینی ورشکستگی ابزارهای تحلیلی ارزشمندی هستند که توسط کارآفرینان، مؤسسات مالی و سرمایه‌گذاران فردی به طور یکسان مورد استفاده قرار می‌گیرند. با این حال، علی‌رغم

استفاده از روش‌های پیچیده، اثربخشی آن‌ها همچنان نیاز به بهبود دارد (Wang and Liu, 2021). ممکن است دلایل زیادی برای غیرقابل‌اعتماد بودن مدل‌های ورشکستگی وجود داشته باشد. برخی از ورشکستگی‌ها را نمی‌توان پیش‌بینی کرد؛ زیرا ناشی از حوادث ناگهانی، غیرمعمول و غیرمنتظره است. در برخی موارد، مشکل ممکن است ناشی از روش‌های ضعیف پیش‌بینی ورشکستگی باشد. همچنین این احتمال وجود دارد که اشتباهات در پیش‌بینی ورشکستگی به کیفیت پایین داده‌های منتشرشده در صورت‌های مالی مرتبط باشد. داده‌های غیرقابل‌اعتماد می‌تواند از اشتباهات غیرعمدی حسابداران و دست‌کاری عمدی صورت‌های مالی ناشی شود (Lohmann et al., 2022).

در طول دوره ۱۹۳۰ الی ۱۹۶۵، مطالعات کمی در مورد پیش‌بینی ورشکستگی انجام شده است. مطالعات اولیه در مورد استفاده از تحلیل نسبت‌های مالی در پیش‌بینی ورشکستگی شرکت‌ها از نوع تحلیل تک‌متغیره بوده و مهم‌ترین آن‌ها مدل بیور (Beaver, 1966) می‌باشد. در سال ۱۹۶۸، آلتمن (Altman, 1968) برای اولین بار از روش‌های تحلیلی تشخیصی چندگانه برای پیش‌بینی ناتوانی کسب‌وکار استفاده کرد. در سال ۱۹۸۰، اولسون و همکاران (Olson et al., 1980) یک مدل تحلیل لاجیت برای پیش‌بینی ورشکستگی معرفی کرد. مدل لاجیت تعدادی از ویژگی‌ها یا مشخصات شرکت را ترکیب می‌کند که از طریق آن، یک احتمال برای آن شرکت محاسبه می‌شود. این عدد نشان‌دهنده احتمال ورشکستگی یا آسیب‌پذیری در برابر ورشکستگی است. روند مطالعات نشان می‌دهد که اگرچه مدل‌های آماری می‌توانند پیش‌بینی‌های خوبی برای ورشکستگی شرکت‌ها ارائه دهند؛ اما مفروضات محدودکننده برخی از این مدل‌ها مانند خطی بودن، نرمال بودن و استقلال متغیرهای پیش‌بین بر اثربخشی آن‌ها تأثیر گذاشته است؛ بنابراین، برای غلبه بر این محدودیت‌ها و بهبود عملکرد پیش‌بینی‌ها، تکنیک‌های هوش مصنوعی به تدریج توسعه یافتند. مدل‌های هوش مصنوعی ورشکستگی عمدتاً بر نشانه‌های ناتوانی کسب‌وکار متمرکز هستند. آن‌ها به طور کلی چندمتغیره هستند و متغیرهای به‌کاررفته در آن‌ها از داده‌های صورت‌های مالی استخراج می‌شوند (Alibabaee and Khanmohammadi, 2022). عدم بهبود قابل‌توجه در ویژگی‌های تبعیض‌آمیز مدل‌های پیش‌بینی ورشکستگی، علی‌رغم استفاده از روش‌های پیچیده‌تر، ممکن است به این معنی باشد که علت طبقه‌بندی نادرست شرکت‌ها به دلیل ضعف روش‌های اعمال‌شده نیست؛ بلکه به دلیل کیفیت داده‌های مورد‌استفاده است. به این منظور، افزایش نرخ شناسایی برای شرکت‌های ورشکسته با حذف موارد پرت گزارش‌شده برای شرکت‌هایی که به‌عنوان تداوم فعالیت ادامه می‌دهند، امکان‌پذیر است (Pawełek, 2019). به طور مشابه، تسای و چنگ (Tsai and Cheng, 2012) نشان می‌دهند که حذف نقاط پرت، دقت پیش‌بینی مدل‌ها را بهبود می‌بخشد. باتوجه‌به وانگ و لیو (Wang and Liu, 2021)، بهبود عملکرد مدل با

افزایش نرخ نمونه‌برداری کمتر امکان‌پذیر است. از سوی دیگر، کارپوف و همکاران (Karpoff *et al.*, 2017) خاطر نشان کردند که زیربنای اشکالات پایگاه‌های داده مورد استفاده در مدل سازی ورشکستگی است: حذف داده‌ها، به‌ویژه درست قبل از سال ورشکستگی و به‌ویژه در مورد شرکت‌های کوچک‌تر یا جوان‌تر؛ بنابراین، آن‌ها تأکید می‌کنند که کیفیت داده‌ها برای پیش‌بینی ورشکستگی بسیار مهم است. موچکو و آدامچیک (Mućko and Adamczyk, 2023)، در پاسخ به این سؤال است که آیا غیرقابل اعتماد بودن مدل پیش‌بینی ورشکستگی آلتمن ممکن است ناشی از دست‌کاری در صورت‌های مالی باشد یا خیر؟ پرداخته‌اند. در این مطالعه، شرکت‌ها به دو گروه تقسیم شده‌اند: شرکت‌هایی که به‌درستی توسط مدل آلتمن به‌عنوان در معرض خطر ورشکستگی طبقه‌بندی شده‌اند و شرکت‌هایی که مدل ریسک ورشکستگی قابل توجهی را برای آن‌ها نشان نمی‌دهد. با استفاده از مدل لاجیت، آزمایش شده است که آیا احتمال دسته‌بندی صحیح شرکت‌ها به‌عنوان شکست‌خورده به خطر دست‌کاری صورت‌های مالی بستگی دارد یا خیر. از قانون بنفورد برای اندازه‌گیری ریسک دست‌کاری صورت‌های مالی استفاده شده است. نتایج نشان داد که دست‌کاری صورت‌های مالی دلیل پیش‌بینی‌های نادرست مدل آلتمن نیست. در مقابل، نتایج نشان داد دست‌کاری برای شرکت‌هایی با امتیاز Z پایین‌تر و در نتیجه وضعیت مالی بدتر رخ می‌دهد. این بدان معناست که بدتر شدن کیفیت صورت‌های مالی می‌تواند سیگنالی از افزایش احتمال ورشکستگی باشد.

لوحمان و همکاران (Lohmann *et al.*, 2022)، از مدل‌های افزایشی تعمیم‌یافته برای شناسایی و تجزیه و تحلیل روابط غیرخطی بین متغیرهای مستقل مبتنی بر حسابداری و مبتنی بر بازار و چگونگی تأثیر آن‌ها بر پیش‌بینی ورشکستگی استفاده کرده‌اند. نتایج نشان داد که پیش‌بینی ورشکستگی تحت تأثیر روابط غیرخطی مرتبط آماری و اقتصادی است. همچنین در نظر گرفتن این روابط غیرخطی چندین معیار اعتبار آماری را به طور قابل توجهی بهبود می‌بخشد. همچنین از یک معیار اعتبار استفاده کرده‌اند که بر اساس سودآوری مدل‌های پیش‌بینی ورشکستگی در زمینه امتیازدهی اعتباری است. یافته‌ها نشان داد که در نظر گرفتن روابط غیرخطی می‌تواند به طور قابل توجهی قدرت تبعیض‌آمیز مدل‌های پیش‌بینی ورشکستگی را افزایش دهد.

سارویی و همکاران (Saroei *et al.*, 2022)، به بررسی مقایسه دقت پیش‌بینی سیستم شبکه‌های عصبی مصنوعی بر مبنای رویکرد پرسپترون چندلایه و مدل باینری - لجستیک فالمر در راستای پیش‌بینی ورشکستگی پرداخته‌اند. یافته‌ها نشان داد که سیستم شبکه‌های عصبی مصنوعی بر مبنای رویکرد پرسپترون چندلایه قادر هستند با دقتی معادل ۹۸ درصد عوامل تأثیرگذار بر ورشکستگی شرکت‌های ایرانی را در سال قبل از ورشکستگی شناسایی نماید. یافته‌های حاصل از بررسی مدل

باینری - لجستیک نشان داد که الگوی پیش‌بینی طراحی شده بر اساس روش رگرسیون فالمر قادر است با دقت ۸۲ درصد ورشکستگی شرکت‌های نمونه را مورد پیش‌بینی قرار دهد.

حیدری و همکاران (Heidary et al., 2021)، دو مدل پیش‌بینی ورشکستگی با استفاده از شبکه عصبی و الگوریتم فراابتکاری کرم شبتاب در بورس اوراق بهادار تهران، آزمون و نتایج با هم مقایسه کرده‌اند. یافته‌های این پژوهش نشان داد که شبکه عصبی بهینه‌شده به‌وسیله الگوریتم کرم شبتاب عملکرد بهتری نسبت به شبکه عصبی پس انتشار خطا در پیش‌بینی ورشکستگی شرکت‌های نمونه دارد. همچنین الگوریتم کرم شبتاب به‌خوبی نسبت بین شرکت‌های ورشکسته و عدم ورشکسته را همانند داده‌های واقعی حفظ کرده است.

حق‌پرست و همکاران (Haghparast et al., 2021)، با هدف به‌کارگیری شبکه عصبی کانولوشن برای پیش‌بینی ورشکستگی شرکت‌ها با استفاده از نسبت‌های مالی تصویری انجام داده‌اند. نتایج حاصل از تحلیل یافته‌ها نشان داد که مدل شبکه‌های عصبی کانولوشن در پیش‌بینی و شناخت از روی تصاویر، پیش‌بینی درستی با دقت ۵۰ درصد از بین شرکت‌ها انجام داد. به عبارتی در پیش‌بینی وضعیت تداوم فعالیت شرکت‌ها ۵۰ درصد از شرکت‌های ورشکسته و ۵۰ درصد از شرکت‌های غیر ورشکسته را درست تشخیص داده است.

باتوجه به مبانی نظری و پیشینه پژوهش، سؤال اصلی به این صورت بیان می‌شود:

کدام یک از مدل‌های پیش‌بینی ورشکستگی بر اساس ۹ معیار کلیدی میزان ورشکستگی را با دقت بهتری پیش‌بینی می‌کند؟

۳- روش‌شناسی پژوهش

مطالعه حاضر یک بررسی مروری سیستماتیک می‌باشد. برای جمع‌آوری مقالات موردنیاز می‌توان از پایگاه‌های علمی گوگل اسکالر، وایلی اینترساینس، ساینس دایرکت، وب آو ساینس و بیزینس سورس کامپلت کمک گرفت که در این پژوهش با استفاده از وب آو ساینس داده‌های موردنیاز استخراج شده است. برای جستجو اولیه در پایگاه مذکور کلیدواژه‌های مانند Distress, Default, Bankruptcy, Prediction, Forecasting, Failure و همچنین از عملگرهای AND, OR و NOT در فیلد عنوان (Title) استفاده گردید تا موتور جستجو بتواند حتی‌الامکان تمام مقالات موجود را بیابد. از بین حالات احتمالی تنها کلیدواژه‌ای که تعداد قابل توجهی مقاله یافت شد، واژه Bankruptcy می‌باشد. نتایج حاصل از جستجوی اولیه ۱۰۰۰ مقاله بود که برای رسیدن به اسناد

مرتبط با موضوع پژوهش با استفاده از فیلترهای محدودکننده تعبیه‌شده (فیلترهایی مانند نوع سند، نوع زبان انتشار مقالات، سال انتشار و حوزه‌های وب آو ساینس) در این پایگاه غربال گردید. با اعمال اولین فیلتر در قسمت نوع سند (انتخاب Article) ۴۰۰ مقاله و با انتخاب زبان انگلیسی ۵۱ مقاله حذف شدند. همچنین با اعمال محدودیت بازه زمانی ۲۰۱۵ الی ۲۰۲۳ تعداد ۲۳۴ مقاله و با انتخاب حوزه Business (به علت نزدیکی بودن به حوزه حسابداری) تعداد ۲۶۶ مقاله از نظر عدم ارتباط موضوعی حذف گردیده و ۴۹ مقاله نهایی مرتبط با هدف مطالعه، شناسایی و انتخاب شدند. باتوجه به اینکه پایگاه علمی وب آو ساینس به طور دائم در حال به‌روزرسانی است لذا اگر پژوهشگری در زمانی دیگر این جستجو را انجام دهد احتمالاً به نتایج مستقلی برسد که با نتایج حاضر هم‌خوانی نداشته باشد.

۴- تجزیه و تحلیل داده‌ها

این بخش به ارائه نتایج، تجزیه و تحلیل و بحث بررسی نظام‌مند به صورت جداول خلاصه یافته‌ها و نمودارهای آماری پرداخته شده است. نتایج هر معیار شناسایی شده ارائه شده است. جداول و نمودارها عملکرد و توانایی ابزارها را باتوجه به تمام مطالعات مورد بررسی مقایسه نمودند.

مطالعه حاضر به بررسی هشت ابزار مورد استفاده برای تدوین مدل‌های پیش‌بینی ورشکستگی پرداخته است که عبارت‌اند از: تحلیل شخصیتی چندگانه^۱، رگرسیون لجستیک^۲، شبکه عصبی مصنوعی^۳، ماشین‌های بردار پشتیبان^۴، مجموعه‌های راف^۵، استدلال مبتنی بر مورد^۶، درخت تصمیم‌گیری^۷ و الگوریتم ژنتیک^۸.

تحلیل شخصیتی چندگانه، روشی است چندمتغیره که پدیده‌ها را بر اساس ویژگی‌های آن‌ها به گروه‌های مانع‌الجمع طبقه‌بندی می‌کند. هدف اصلی این الگو تشخیص تفاوت بین گروه‌ها و پیش‌بینی احتمال تعلق یک شرکت به یک گروه خاص است. در تحلیل شخصیتی چندگانه برای انجام این پیش‌بینی از چندین متغیر مستقل کمی استفاده می‌شود (Jackson and Wood, 2013). در حقیقت روش آماری است که از آن برای دسته‌بندی مشاهده‌ها به گروه‌های از پیش تعیین شده استفاده می‌شود.

1. Multivariate Statistical Models (MDA)
2. Logistic Regression (LR)
3. Artificial Neural Network (ANN)
4. Support Vector Machines (SVM)
5. Rough Sets (RS)
6. Case Based Reasoning (CBR)
7. Decision Tree (DT)
8. Genetic Algorithm (GA)

مدل‌های تحلیل شخصیتی چندگانه به صورت یک معادله ریاضی بیان می‌شوند و از نسبت‌های مالی استفاده می‌کند که شرکت‌ها را در یکی از دو گروه درمانده و غیر درمانده متمایز می‌کند. تابع تحلیل شخصیتی چندگانه به صورت رابطه (۱) است.

$$Z = c_1X_1 + c_2X_2 + \dots + c_nX_n \quad \text{رابطه (۱)}$$

رگرسیون لجستیک، یک مدل آماری برای متغیرهای وابسته دو بعدی مانند ورشکسته شدن یا نشدن و... است. این مدل، یک مدل خطی تعمیم‌یافته است که از تابع لجوجیت به عنوان تابع پیوند استفاده می‌کند و جمله خطای آن از توزیع چندجمله‌ای پیروی می‌کند. این مدل از تکنیک حداکثر لگاریتم - درست‌نمایی غیرخطی برای برآورد احتمال ورشکستگی شرکت، تحت فرض توزیع لجستیک استفاده می‌کند (Zambrano Farias et al., 2021). تابع رگرسیون لجستیک به صورت رابطه (۲) است.

$$P_1(V_i) = 1 \div [1 + \exp - (b_0 + b_1V_{i1} + b_2V_{i2} + \dots + b_nV_{in})] = 1 \div [1 + \exp - (D_i)] \quad \text{رابطه (۲)}$$

مدل شبکه عصبی، تقلید از طرز کار سیستم عصبی فعالیت‌های مغزی انسان است (Appiah et al., 2015) و نخستین بار توسط اودوم و شاردا (Odom and Sharda, 1990) برای پیش‌بینی ورشکستگی استفاده شد. یک مدل شبکه عصبی معمولی شبکه‌ای از گره‌های به هم پیوسته در لایه‌های مختلف است که با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. در این روش یادگیری با استفاده از مثال‌ها و یا به کارگیری ساختارها و الگوریتم‌های ذهن انسان انجام می‌شود (Pourgadimi et al., 2022).

مدل ماشین‌های بردار پشتیبان، در حل مسائل مربوط به طبقه‌بندی، عملکرد بسیار خوبی از خود نشان داده است و در سال‌های اخیر در کشورهای توسعه‌یافته برای پیش‌بینی درماندگی مالی و ورشکستگی مورد توجه واقع شده است (Ravi Kumar and Ravi, 2007). ماشین‌های بردار پشتیبان، الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کنند. حداکثر کردن حاشیه ابر صفحه منجر به حداکثر شدن تفکیک بین طبقات می‌شود. به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان اطلاق می‌گردد. تنها از این بردارها (نقاط) برای مشخص کردن مرز بین طبقات استفاده می‌شود (Dreiseitl and Ohno-Machado, 2002).

مدل مجموعه‌های راف که توسط پاولک (Pawlak, 1982) کشف شد فرض می‌کند که اطلاعاتی در ارتباط با تمام اشیای (شرکت‌های) یک دنیای خاص وجود دارد؛ این اطلاعات ویژگی‌هایی (متغیرهایی) را که قادر به توصیف این اشیاء هستند ارائه می‌دهند. مجموعه‌های راف تقسیم اشیاء با ویژگی‌های مشابه را در بلوک‌هایی (مانند بلوک‌های شکست و موفقیت) به نام مجموعه‌های ابتدایی

تفکیک می‌کند (Greco et al., 2001). اشیایی که در خط مرزی قرار می‌گیرند را نمی‌توان طبقه‌بندی نمود؛ زیرا اطلاعات مربوط به آن‌ها مبهم است. از مجموعه‌های راف برای استخراج قوانین تصمیم‌گیری در حل مسائل طبقه‌بندی استفاده می‌شود (Ravi Kumar and Ravi, 2007 and Greco et al., 2001).

استدلال مبتنی بر مورد، اساساً نسبت به ابزارهای دیگر متفاوت بوده و طبقه‌بندی یک شرکت را بر اساس ویژگی‌های مشابه سایر شرکت‌ها با آن شرکت، انجام می‌دهد (Shin et al., 2005). به عبارت دیگر، روش استدلال مبتنی بر مورد بر اساس استفاده از پاسخ مسائل قبلی برای حل مسائل مشابه جدید شکل گرفته است. استدلال مبتنی بر مورد به‌عنوان روشی شناخته می‌شود که از نحوه رفتار انسان‌ها در برخورد با مسائل جدید الگوبرداری کرده است؛ به این ترتیب که از تجربیات کسب‌شده در حل مسائل گذشته به‌عنوان راهنمایی برای حل مسائل جدید بهره می‌برد.

درخت تصمیم‌گیری، قوانین تصمیم‌گیری را ارائه می‌کند. موقعیت قوانین در درخت تصمیم‌گیری معمولاً با استفاده از شیوه‌های اکتشافی تعیین می‌شود (Almaskati et al., 2021). درخت تصمیم یکی از روش‌های ناپارامتری رده‌بندی کردن است. این روش با به‌کارگیری تکنیک‌های بسیار ساده، یک الگوی رده‌بندی را برای مشاهدات موجود معرفی می‌نماید. الگوی معرفی‌شده توسط این روش، از ساختاری بسیار ساده و قابل درک برای تصمیم‌گیری برخوردار است. با اینکه این روش از تکنیک‌های ساده‌ای استفاده می‌نماید ولی در زمینه تشخیص و پیشگویی می‌تواند به‌خوبی روش‌های پیچیده‌ای نظیر شبکه‌های عصبی عمل نماید.

الگوریتم ژنتیک، یک روش جستجوی احتمالی است که از شبیه‌سازی تکاملی زیستی و طبیعی استفاده می‌کند. الگوریتم‌های ژنتیکی با به‌کارگیری اصل بقای بهترین‌ها برای تولید تخمین‌های هر چه بهتر یک جواب روی جمعیتی از جواب‌های بالقوه عمل می‌نماید.

پژوهشگران مختلف از معیارهای مختلفی برای توسعه مدل پیش‌بینی ورشکستگی خود استفاده نمودند؛ با این حال پس از بررسی کامل و جامع مطالعات اولیه و مطالعات دیگر در این حوزه، ۹ معیار رایج و مهم مشخص شدند که عبارت‌اند از:

۱) دقت: این معیار مربوط به درصد شرکت‌هایی است که یک ابزار به‌درستی تحت عنوان شکست یا موفقیت طبقه‌بندی می‌کند.

۲) شفافیت نتایج: این معیار با قابلیت تفسیر نتایج یک ابزار سر و کار دارد.

۳) اندازه نمونه: این معیار به‌اندازه نمونه مناسب برای عملکرد بهینه ابزار اشاره می‌کند.

۴) پراکندگی داده‌ها: این معیار به توانایی ابزار برای مقابله با داده‌های با پراکنش برابر یا نابرابر اشاره دارد.

۵) انتخاب متغیر: این معیار به روش‌های انتخاب متغیرهای لازمه برای عملکرد بهینه ابزار اشاره دارد.

۶) هم‌خطی چندگانه: این معیار به حساسیت ابزار به متغیرهای هم‌خطی اشاره دارد.

۷) نوع متغیر: قابلیت ابزار برای تحلیل متغیرهای کمی و یا کیفی.

۸) بیش برآزش^۱ و تعمیم‌پذیری نمونه: این امر زمانی رخ می‌دهد که مدل توسعه‌یافته ابزار در شرکت نمونه عملکرد خوبی داشته؛ اما در داده‌های اعتبارسنجی بد عمل می‌کند.

۹) قابلیت به‌روزرسانی: سهولت به‌روزرسانی مدل ابزار با شرکت نمونه جدید و اثربخشی آتی آن.

این ۹ معیار را می‌توان در سه دسته اصلی گروه‌بندی نمود که در **جدول (۱)** ارائه گردید. این دسته‌ها عبارت‌اند از: ۱) معیارهای مربوط به نتایج، ۲) معیارهای مربوط به داده‌ها، ۳) معیارهای مربوط به ویژگی‌های ابزار.

جدول (۱) معیارهای مهم موردنیاز برای ابزارهای مدل پیش‌بینی ورشکستگی

Table (1) important criteria required for bankruptcy prediction model tools

معیارهای مربوط به نتایج	معیارهای مربوط به داده‌ها	معیارهای مربوط به ویژگی‌های ابزار
دقت	قابلیت اندازه نمونه	بیش برآزش و تعمیم‌پذیری
تفسیر نتایج	پراکندگی داده‌ها	قابلیت به‌روزرسانی
-	انتخاب متغیر	-
-	هم‌خطی چندگانه	-
-	نوع متغیرهای کاربردی	-

یکی از دلایل اصلی استفاده از ابزارهای مختلف برای توسعه مدل پیش‌بینی ورشکستگی، افزایش دقت پیش‌بینی است. **جدول (۲)** مقدار دقت هر ابزار را طبق گزارش‌های هر مطالعه نشان می‌دهد.

جدول (۲) خلاصه مقادیر دقت مطالعات بررسی شده

Table (2) summarizes the accuracy values of the reviewed studies

مقادیر دقت							نویسنده / سال
ماشین‌های بردار پشتیبان	شبکه عصبی مصنوعی	درخت تصمیم‌گیری	مجموعه‌های راف	الگوریتم ژنتیک	استدلال مبتنی بر مورد	تحلیل شخصی چندگانه	رگرسیون لجستیک
-	۹۳/۷۵	-	-	-	-	-	۸۶/۲۵
-	۷۱/۸	۶۵/۷	-	-	۷۷/۷	-	۷۲/۲
-	۷۱/۰۲	-	-	-	-	-	-
۷۴/۲	۷۳/۱	-	-	-	-	۷۰/۱	۷۰/۱

۹۲/۰۱	۸۷/۲۰	-	-	-	-	۹۴/۰۳	-	دو جاردین (Du Jardin, 2010)
-	۹۰/۷۴	-	-	-	-	-	۹۴/۴۴	لین و همکاران (Lin et al., 2010)
-	۸۴/۵	-	-	-	۷۶/۶	-	-	چپ و همکاران (Gepp et al., 2010)
۸۶/۵۶	۹۱/۴۴	-	-	-	-	۹۲/۳۸	-	دی آندرس و همکاران (De Andrés et al., 2011)
۸۰	۷۲/۶	-	-	-	-	۹۱/۶	۹۵/۹۵	کیم (Kim, 2011)
-	-	-	-	-	-	۷۸/۳۳	۷۹	یانگ و همکاران (Yang et al., 2011)
-	-	-	-	-	-	-	-	چن (Chen, 2011)
۸۰	-	-	۹۵	-	-	۸۲/۵	-	دیوسالار و همکاران (Divsalar et al., 2011)
۸۱/۱۴	۸۱/۹۳	-	-	-	-	۸۲/۶۲	-	دو جاردین و سورین (Du Jardin and Séverin, 2011)
-	-	-	۸۶/۷	-	-	۹۰/۶	۹۰	چن و همکاران (Chen et al., 2011)
-	-	-	۸۲/۳۳	-	-	۷۹/۵۸	۷۶/۶۷	چن همکاران (Chen et al., 2011)
۸۷/۵۰	۸۸/۲۶	-	-	۸۸/۴۶	-	-	-	لی و همکاران (Li et al., 2011)
۷۶/۴۷	-	-	۹۱/۱۸	-	-	۷۹/۴۱	-	دیوسالار و همکاران (Divsalar et al., 2012)
۷۷/۹	-	-	-	-	۸۳/۲۴	۸۳/۶۷	۸۶/۶۱	هوانگ و همکاران (Huang et al., 2012)
۸۶/۳۷	-	-	-	-	۸۴/۶۹	۸۶/۰۶	۸۶/۳۷	تسای و چنگ (Tsai and Cheng, 2012)
۷۲/۷۳	-	-	-	-	۷۷/۷۷	۷۵/۷۶	۸۱/۸۲	شی و همکاران (Shie et al., 2012)
۸۸/۵	-	-	-	-	۸۸/۸	۸۸/۷	-	کریستوف و ویراز (Kristóf and Virág, 2012)
۷۶/۴۸	۷۳/۵	۷۳	-	-	۷۶	۸۱	۷۹	جنونگ و همکاران (Jeong et al., 2012)
۸۱/۶	۸۱/۲	-	-	-	-	۸۱/۳	-	دو جاردین و سورین (Du Jardin and Séverin, 2012)
-	۷۴/۸۷	-	-	-	-	۷۶/۰۳	-	دی آندرس و همکاران (De Andrés et al., 2012)
۵۴/۴	۶۴/۴	-	-	-	۷۵/۶	۶۷/۸	۷۱/۱	زو و همکاران (Zhou et al., 2012)
-	-	-	-	-	-	-	۷۰/۹۴	شیونگ و همکاران (Xiong et al., 2013)
-	۸۲/۰۱	-	-	-	-	۹۲	-	لی و چوی (Lee and Choi, 2013)
۷۹/۱۱	-	-	-	-	۷۷/۳۹	۷۸/۸۲	-	تسای و هسو (Tsai and Hsu, 2013)
-	-	-	-	-	-	۹۲/۱۱	-	کالجهون و همکاران (Callejón et al., 2013)
-	-	۹۰/۱	-	-	-	-	-	چوانگ (Chuang, 2013)
۹۳	-	-	-	-	-	-	-	هو و همکاران (Ho et al., 2012)
-	-	-	-	-	-	۷۱	۷۰/۴۴	آریشانتی و همکاران (Arieshanti et al., 2013)
۹۱/۴۳	-	-	۸۸/۵۷	-	-	۹۴/۱۱	-	احمدپور کسگری و همکاران (Ahmadpour Kasgari et al., 2013)
۷۳/۹۹	۷۱/۷۲	-	-	-	۵۰/۶۷	۷۵/۶	-	زو و همکاران (Zhou et al., 2012)
۷۷/۲۸	-	-	-	-	۸۶/۸۳	۹۱/۶۱	-	تسای (Tsai, 2014)
-	-	-	-	۹۶/۹۹	۹۱/۵۵	۹۲/۹۵	۹۴/۵۸	یه و همکاران (Yeh et al., 2014)
۷۳/۹۰	-	-	-	-	۷۵/۹۹	۷۵/۶۹	۷۹/۹۹	وانگ و همکاران (Wang et al., 2014)
-	-	-	-	۹۳/۶۴	-	-	-	آبلان و منتاس (Abellán and Mantas, 2014)
۷۹/۱۸	-	-	-	-	-	-	-	تسرنگ و همکاران (Tserng et al., 2014)
-	۸۶/۵	-	-	-	-	-	۹۳/۲	یو و همکاران (Yu et al., 2014)
۶۸/۸	-	-	۷۱/۵	-	-	-	۶۹/۵	جاردینی (Gordini, 2014)
-	۵۱/۳	-	-	-	۷۳/۱	۷۷/۱	۷۳/۳	هنو و یانگ (Heo and Yang, 2014)
-	-	-	-	-	۸۶/۳۷	۸۴/۳۸	۸۶/۳۷	تسای و همکاران (Tsai et al., 2014)
-	-	-	-	۸۹/۳۳	-	۸۸/۰۳	۸۹/۳۳	ویراز و نیترای (Virág and Nyitrai, 2014)


-	-	-	-	-	۹۲/۹۸	۹۱/۶۳	۹۱/۷۷	لیانگ و همکاران (Liang et al., 2015)
۸۱/۷۳	۷۷/۸۸	-	-	-	-	۹۳/۲۷	۸۹/۴۲	لوپز ایبریگا و سانز (López Iturriga and Sanz, 2015)
۸۰/۶	۸۰/۱	-	-	-	-	۸۰/۸	-	دو جاردین (Du Jardin, 2015)
-۰/۳۰۱	-۰/۲۰۷	-۰/۱۹۹	-	-	-	-۰/۲۹۱	-	بمس و همکاران (Bems et al., 2015)
۸۰	۷۷	-	-	-	۹۴	۹۴	-	خادم‌القرآنی و همکاران (Khademolgorani et al., 2015)

جدول (۳) خلاصه آمار دقت

Table (3) summary of accuracy statistics

ابزار	تعداد نویسندگان که از ابزار استفاده کرده‌اند	تعداد نویسندگانی که مقدار دقت را گزارش کرده‌اند
تحلیل شخصیتی چندگانه	۲۴	۲۲
رگرسیون لجستیک	۲۸	۳۷
شبکه عصبی مصنوعی	۱۹	۱۷
ماشین‌های بردار پشتیبان	۴	۴
مجموعه‌های راف	۱۰	۶
استدلال مبتنی بر مورد	۴	۳
درخت تصمیم‌گیری	۲۱	۱۹
الگوریتم ژنتیک	۳۱	۲۸
کل	۵۱	۱۳۶
میانگین	۶/۲۷۵	۱۷

میانگین دقت



شکل (۱) نمودار میانگین دقت کلی هر ابزار

Figure (1) graph of the overall average accuracy of each tool

شکل (۱)، نمودار میانگین دقت را به ازای هر ابزار نشان می‌دهد. این نمودار بر اساس تمام مطالعاتی محاسبه شده که دقت هر ابزار را ارائه کرده‌اند. میانگین تعداد مطالعاتی که مقدار دقت را گزارش کرده‌اند ۱۷ مطالعه می‌باشد (جدول ۳). شکل (۱) به‌وضوح نشان می‌دهد شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان دارای بیشترین دقت می‌باشند درحالی‌که تحلیل شخصیتی چندگانه به ظاهر دارای کمترین دقت است.

برای سرمایه‌گذاران و مشتریان بالقوه، سالم‌بودن یا در شرف ورشکستگی بودن یک شرکت طبق پیش‌بینی کافی است. باین‌حال، برای مالکان شرکت، ارزش مدل پیش‌بینی متفاوت است. اگر شرکتی بر اساس یک مدل پیش‌بینی، به‌عنوان شرکت در شرف ورشکستگی طبقه‌بندی شود، این طبقه‌بندی باید به‌گونه‌ای تفسیرپذیر باشد که مدیران اقدامات لازم برای جلوگیری از ورشکستگی کامل شرکت را انجام دهند.

برخی از مطالعات نشان دادند که درک و تفسیر نتایج مدل‌های شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان که در آن اوزان و ضرایب اختصاص یافته به متغیرها غیرمنطقی است، کاملاً دشوار می‌باشد (Tam and Kiang, 1992 and Shin et al., 2005).

مطابق اظهارات حداقل پنج مطالعه بررسی شده در جدول (۲) و همچنین مطالعات قدیمی‌تر (Boritz and Kennedy, 1995)، ضرایب متغیر در رگرسیون لجستیک نشان‌دهنده اهمیت متغیرها بوده و لذا نتایج آن شفاف می‌باشد و به کاربران در شناسایی حوزه‌های کلیدی مسئله یک شرکت ناموفق کمک می‌کند. مطابق اظهارات حداقل پنج مطالعه بررسی شده در جدول (۲) و برخی مطالعات گذشته (Tam and Kiang, 1992; Shin et al., 2005 and Ravi Kumar and ravi, 2007)، ابزارهای هوش مصنوعی یعنی (مجموعه‌های راف، استدلال مبتنی بر مورد، الگوریتم ژنتیک و درخت تصمیم‌گیری) همگی نتایج توضیحی ارائه می‌نمایند که به‌راحتی تفسیر و درک می‌شوند. آلتمن (Altman, 1968) و تام و کیانگ (Tam and Kiang, 1992) خاطر نشان ساختند اگرچه به نظر تابع تحلیل شخصیتی چندگانه نتایج این ابزار را به‌راحتی تفسیرپذیر می‌سازد؛ اما ضرایب متغیرها در تابع اهمیت آن‌ها را نشان نداده و لذا تفسیر نتایج دشوار می‌باشد. علاوه بر این، تحلیل شخصیتی چندگانه گاهی مدلی را با علائم متضاد نشان می‌دهد.

پراکندگی یکی از مهم‌ترین مفاهیم در آمار است. هرچه پراکندگی کمتر باشد، پیش‌بینی مقدار یک متغیر تصادفی با کمک مقدار میانگین آن دقیق‌تر می‌شود؛ به‌عبارت‌دیگر، پراکندگی می‌تواند دقت یک پیش‌بینی را نشان دهد. در مطالعات ورشکستگی، پراکندگی داده‌ها یعنی نسبت تعداد شرکت‌های نمونه غیر ورشکسته به شرکت‌های نمونه ورشکسته که شاخص کلیدی عملکرد تلقی می‌شود؛ از این‌رو داشتن پراکندگی مساوی بهترین حالت خواهد بود.

تحلیل شخصیتی چندگانه نسبت به پراکندگی نابرابر، بسیار حساس است؛ اما شبکه عصبی مصنوعی قبل از آنکه بتواند الگویی را تشخیص دهد به حداقل پراکندگی ۲۰ شرکت‌های ناموفق نیاز دارد (Boritz and Kennedy, 1995). بهترین گزینه استفاده از داده‌های با پراکندگی برابر است که


اکثر مطالعات چنین هستند. اکثر مطالعات مروری دارای پراکنش داده‌های بین ۵۰ - ۴۰ و ۶۰ - ۵۰ (شکل ۲) بوده و تقریباً نیمی از آن‌ها از داده‌های با پراکندگی برابر استفاده می‌کنند (جدول ۳).



شکل (۲) نسبت مطالعاتی که از پراکندگی داده‌های برابر یا تقریباً برابری استفاده می‌کنند.

Figure (2) Proportion of studies using equal or nearly equal data dispersion.

اندازه نمونه موجود برای تحلیل نیز بر عملکرد یک ابزار تأثیر گذاشته و بنابراین قبل از انتخاب یک ابزار باید مورد توجه جدی قرار گیرد. حداقل دو مطالعه بررسی شده مشخصاً تأیید نمودند که شبکه عصبی مصنوعی و تحلیل شخصیتی چندگانه به نمونه آموزشی بزرگی نیاز دارند تا الگویی را منطقاً شناسایی کرده و طبقه‌بندی بسیار دقیقی ارائه دهند (Shin et al., 2005 and Ravi Kumar and Ravi, 2007). به گفته شین و همکاران (Shin et al., 2005)، ابزار شبکه عصبی مصنوعی به نمونه‌ای حداقل شامل ۱۰۰۰ شرکت جهت تعمیم‌پذیری نیاز دارد. این امر معمولاً در بسیاری از مطالعات شبکه عصبی مصنوعی اجرا نمی‌شود (Shin et al., 2005) که در این مطالعه نیز مشهود است (شکل ۳). با این حال، ویسلون و شاردا (Wilson and Sharda, 1994) توانستند نشان دهند که شبکه عصبی مصنوعی هنوز هم منطقاً عملکرد خوبی دارند (بهتر از مدل‌های آماری). راوی کومار و راوی (Ravi Kumar and Ravi, 2007) گزارش دادند که درخت تصمیم‌گیری و رگرسیون لجستیک به نمونه‌های بزرگی برای عملکرد مناسب نیاز دارند.



شکل (۳) نسبت مطالعاتی که کمابیش از اندازه نمونه ۱۰۰۰ شرکت برای شبکه عصبی مصنوعی استفاده می‌کنند.

Figure (3) Proportion of studies that use more or less the sample size of 1000 companies for artificial neural network.

استدلال مبتنی بر مورد، مجموعه‌های راف و ماشین‌های بردار پشتیبان می‌توانند با اندازه نمونه‌های کوچک کار کنند (Ravi Kumar and Ravi, 2007). اگرچه ویلسون و شاردا (Wilson and Sharda, 1994) اظهار نمودند که دقت استدلال مبتنی بر مورد همگام با افزایش اندازه نمونه‌ها افزایش می‌یابد؛ اما راوی کومار و راوی (Ravi Kumar and Ravi, 2007) اظهار داشتند که استدلال مبتنی بر مورد نمی‌تواند با داده‌های بسیار بزرگ کار نماید. حداقل چهار مطالعه بررسی‌شده توانایی ویژه ماشین‌های بردار پشتیبان را در عملکرد مناسب با مجموعه داده‌های کوچک تأیید نمودند (جدول ۳). در مطالعه گسترده خود اظهار نمودند که اکثر مدل‌های مبتنی بر ماشین‌های بردار پشتیبان با کاهش اندازه نمونه‌های آموزشی می‌توانند عملکرد بالا را حفظ نمایند. این امر نشان می‌دهد که مدل‌های ماشین‌های بردار پشتیبان می‌توانند عملکرد خوبی با نمونه‌های آموزشی کوچک داشته باشند. در حقیقت شین و همکاران (Shin et al., 2005) ثابت کردند که عملکرد ماشین‌های بردار پشتیبان با داده‌های آموزشی کوچک برخلاف داده‌های بزرگ بهتر و بهینه‌تر است. این مزیت ماشین‌های بردار پشتیبان در مطالعات قدیمی‌تر نیز تأیید گردید (Ravi Kumar and Ravi, 2007).

هم‌خطی چندگانه زمانی اتفاق می‌افتد که دو یا بیش از دو متغیر توضیح‌دهنده (مستقل) در یک تحلیل رگرسیون چندمتغیره نسبت به یکدیگر از همبستگی بالایی برخوردار باشند. منظور از همبستگی در اینجا وجود یک ارتباط خطی بین متغیرهای مستقل است.

ابزارهای آماری به‌ویژه رگرسیون لجستیک، نسبت به هم‌خطی چندگانه به‌شدت حساس و واکنش‌پذیر بوده و باید از روش مؤثری برای انتخاب متغیرهای غیرهم‌خطی برای آن‌ها استفاده شود. هم‌خطی چندگانه می‌تواند به‌راحتی به عملکرد ناپایدار و نتایج نادرستی منجر شود. مطالعات بررسی‌شده مشخصاً نشان می‌دهند که ابزارهای هوش مصنوعی، به‌غیر از استدلال مبتنی بر مورد، نسبت به هم‌خطی

چندگانه حساسیت کمتری داشته و تقریباً با هر روش انتخاب متغیری عملکرد خوبی دارند. عملکرد استدلال مبتنی بر مورد با افزایش تعداد متغیرها کاهش می‌یابد. از سوی دیگر، برخی از مطالعات اظهار داشتند که هر قدر تعداد متغیرها بیشتر باشد، برای شبکه عصبی مصنوعی و GA بهتر خواهد بود. در واقع، عملکرد انتخاب ویژگی (متغیر) همیشه باعث بهبود عملکرد پیش‌بینی ابزارهای هوش مصنوعی نمی‌شود. با این حال، بر این باورند که حذف متغیرهای نامربوط می‌تواند عملکرد را بهبود بخشد.

اگرچه اکثر قریب به اتفاق مطالعات مدل‌های پیش‌بینی ورشکستگی از متغیرهای کمی معمولاً به صورت نسبت‌های مالی استفاده می‌کنند؛ اما همان‌طور که در بسیاری از مطالعات اشاره شد، نمی‌توان بیش از حد بر آن تأکید نمود (Alaka et al., 2016). MDA می‌تواند تنها از متغیرهای کمی استفاده کند (Altman, 1968 and Odom and Sharda, 1990)؛ در حالی که رگرسیون لجستیک می‌تواند از هر دو استفاده کند. شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان می‌توانند به طور عمده از متغیرهای کمی استفاده و متغیرهای کیفی را با استفاده از ابزارهایی مانند مقیاس لیکرت به متغیرهای کمی تبدیل نمایند. همه ابزارهای هوش مصنوعی که در پیش‌بینی ورشکستگی به عبارت‌های (اگر و آنگاه) ختم می‌شوند، مشتمل بر RS، درخت تصمیم‌گیری، استدلال مبتنی بر مورد و الگوریتم ژنتیک، از متغیرهای کیفی استفاده می‌نمایند (Ravi Kumar and Ravi, 2007).

بیش برآزش به پدیده نامطلوبی در آمار گفته می‌شود که در آن درجه آزادی مدل بسیار بیشتر از درجه آزادی واقعی انتخاب شده و در نتیجه اگرچه مدل روی داده استفاده‌شده برای یادگیری بسیار خوب نتیجه می‌دهد؛ اما بر روی داده جدید دارای خطای زیاد است. انتخاب درجه آزادی مناسب به کمک واریانس اعتبار^۱ و تنظیم کردن^۲ از راه‌های مقابله با این پدیده است.

انتخاب متغیر به شیوه گام‌به‌گام که عمدتاً منجر به انتخاب نسبت‌های مالی به‌عنوان متغیر برای ابزارهای آماری می‌شود، گاهی به مدلی منجر می‌شود که عملکرد بسیار خوبی فقط برای نمونه‌های مورد استفاده برای ساخت آن مدل دارد؛ اما متأسفانه باعث می‌شود نمونه‌ها تعمیم‌پذیری پایینی داشته باشند. با این حال رگرسیون لجستیک دارای تعمیم‌پذیری نسبتاً معقولی می‌باشد.

در حال حاضر برای اجتناب از این مشکل (در ابزارهای آماری و هوش مصنوعی) قاعده‌ای وجود دارد که توسط مدل‌های آزمایشی در نمونه اعتبارسنجی (مدل‌سازی مجدد در صورت لزوم) به کار می‌رود. بیش از یک‌سوم مطالعات بررسی‌شده این مشکل را سریعاً شناسایی کرده‌اند و آن را در مرحله توسعه مدل اولیه در نظر گرفتند. البته بیش برآزش و کم برآزش لزوماً در اثر روش انتخاب متغیر یا انواع

1. Cross-validation

2. Regularization

متغیر در مورد ابزارهای هوش مصنوعی ایجاد نمی‌شوند. به‌غیراز مورد استدلال مبتنی بر مورد، باور عمومی بر این است که هرقدر مدل منجر به قوانین تصمیم‌گیری طولانی‌تر (کوتاه‌تر) شود، احتمال بیش برآزش (کم برآزش) بیشتر خواهد بود. استدلال مبتنی بر مورد تمایلی به بیش برآزش ندارد؛ بااین‌حال، استدلال مبتنی بر مورد دارای تصمیم‌پذیری ضعیفی بوده؛ اما این امر به دلیل دقت ضعیف آن است (Ravi Kumar and Ravi, 2007).

بیش برآزش یک مشکل شناخته‌شده در شبکه عصبی مصنوعی است. بااین‌حال، گرایش به بیش برآزش در ماشین‌های بردار پشتیبان کمتر از شبکه عصبی مصنوعی و تحلیل شخصیتی چندگانه است (Shin et al., 2005).

ابزارهای آموزشی هوش مصنوعی، به‌ویژه شبکه هوش مصنوعی و الگوریتم ژنتیک، در قیاس با ابزارهای آماری زمان نسبتاً طولانی‌تری را جهت به‌روزرسانی می‌طلبند. این امر به دلیل فرآیند تکراری یافتن بهترین پارامترها برای ابزارهای هوش مصنوعی است. مطابق اظهارات مطالعات بررسی‌شده، استدلال مبتنی بر مورد و الگوریتم ژنتیک باعث ایجاد مدل‌های پیش‌بینی ورشکستگی با بیشترین قابلیت به‌روزرسانی می‌شوند. به‌روزرسانی استدلال مبتنی بر مورد ساده بوده و پس از به‌روزرسانی کاملاً مؤثر می‌گردد چرا که افزودن موارد جدید زمان‌بر نبوده و پیش‌بینی یک مورد جدید از طریق یافتن موارد مشابه در بین همه موارد قدیمی و جدید انجام می‌پذیرد. به‌روزرسانی مدل‌های پیش‌بینی ورشکستگی آماری می‌تواند منجر به کاهش دقت شود. شبکه عصبی مصنوعی به‌صورت تطبیقی با نمونه‌های جدید به‌روزرسانی می‌شود. بااین‌حال، اگر شرایط موارد جدید تفاوت معنی‌داری با موارد مورد استفاده برای ساخت مدل داشته باشد آنگاه باید مدل جدیدی ایجاد گردد. مجموعه‌های راف به‌ویژه به تغییرات داده‌ها بسیار حساس بوده و پس از به‌روزرسانی با داده‌هایی که تغییرات جدی دارند، غیرمؤثر می‌باشد.

جدول (۴) چهارچوبی را ارائه می‌کند که از نتایج این بررسی حاصل شده و به‌عنوان راهنمایی برای توسعه‌دهندگان مدل‌های پیش‌بینی ورشکستگی در راستای انتخاب ابزار مناسب که بهترین انطباق را با داده‌های موجود و معیارهای اولویت مدل‌های پیش‌بینی ورشکستگی دارد عمل می‌کند.

جدول (۴) به‌وضوح نشان می‌دهد که برای دستیابی به بهترین عملکرد از یک مدل‌های پیش‌بینی ورشکستگی، ابزار درحال توسعه باید بر اساس اولویت‌های معیارهای خروجی و ویژگی‌های داده‌های موجود انتخاب شود. این چهارچوب نقطه شروع خوبی برای توسعه‌دهندگان مدل‌های پیش‌بینی ورشکستگی بوده و تضمین می‌کند که ابزارها با توجه به نواقص توسعه‌دهندگان به‌دلخواه انتخاب نشوند. همچنین این چهارچوب تضمین می‌کند که کاربر نهایی مدل‌های پیش‌بینی ورشکستگی، با انتقال نیازمندی‌های خود به توسعه‌دهندگان مدل به مناسب‌ترین مدل‌های پیش‌بینی ورشکستگی دست یابد.

جدول (۴) دسته‌بندی ابزارها

Table (4) category of tools

دسته‌بندی ابزارها							
ابزارهای هوش مصنوعی				آماري			
استدلال مبتنی بر مورد	درخت تصمیم‌گیری	الگوریتم ژنتیک	مجموعه‌های راف	ماشین‌های بردار پشتیبان	شبکه عصبی مصنوعی	رگرسیون لجستیک	تحلیل شخصیتی چندگانه
کم	متوسط	زیاد	زیاد	خیلی زیاد	خیلی زیاد	متوسط	کم
زیاد	زیاد	زیاد	زیاد	کم	کم	زیاد	کم
زیاد	کم	NR	زیاد	خیلی زیاد	کم	کم	کم
NR	NR	NR	NR	NR	زیاد	عادی	زیاد
هرکدام	هرکدام	هرکدام	هرکدام	هرکدام	هرکدام	SW	SW
کم	کم	کم	کم	کم	کم	خیلی زیاد	زیاد
QN	هر دو	هر دو	QN	QN	QL	هر دو	QN
خبر	بله	بله	بله	بله	بله	بله	بله
ضعیف	ضعیف	OK / خوب	ضعیف	-	OK	ضعیف	ضعیف
زیاد	زیاد	زیاد	زیاد	زیاد	زیاد	کم	کم

پیامد استفاده از چهارچوب ارائه‌شده در جدول (۴) در عمل آن است که به ابزارها اجازه می‌دهد تا باتوجه‌به بهترین نقاط قوت خود استفاده شده و مدل‌های پیش‌بینی ورشکستگی را ترغیب می‌نماید تا به صورتی سفارشی متناسب با نیازمندی‌های مشتریان توسعه یابند. به‌گونه‌ای که برای کاربران و مشتریان مختلف بسیاری مانند سرمایه‌گذاران، مشتریان، مالکان، نهادهای دولتی، حساب‌رسان و غیره به‌اندازه کافی خوب باشد. این روش فرآیند هدررفت زمان توسعه مدل‌های پیش‌بینی ورشکستگی را با ابزارهای متعدد در راستای انتخاب بهترین گزینه پس از مجموعه آزمون‌ها حذف می‌کند. پیامد این کار پژوهشی آن است که راهنمای پژوهشگران در انتخاب بهترین ابزار برای داده‌ها و وضعیت آن‌ها بوده و به اجتناب از انتخاب دلخواهانه ابزارها یا انتخاب مبتنی بر محبوبیت کمک می‌کند. همچنین این پژوهش، پژوهشگران را درباره ضرورت استفاده بیشتر از ابزارهای ترکیبی آگاه می‌نماید. از این رو پژوهش مزبور خواستار توسعه مدل‌های ترکیبی جدید می‌باشد.

۵- بحث و نتیجه‌گیری

حوزه پژوهشی پیش‌بینی ورشکستگی با مدل‌های جدید زیادی که با استفاده از ابزارهای مختلف توسعه می‌یابند به تکامل خود ادامه می‌دهد. با این حال بسیاری از ابزارها با شرایط داده‌های اشتباه و یا وضعیت اشتباه استفاده می‌شوند. در مطالعه حاضر از بررسی نظام‌مند استفاده شد تا نحوه عملکرد هشت ابزار محبوب تحلیل شخصیتی چندگانه، رگرسیون لجستیک، شبکه عصبی مصنوعی، ماشین‌های بردار پشتیبان، مجموعه‌های راف، استدلال مبتنی بر مورد، درخت تصمیم‌گیری و الگوریتم ژنتیک باتوجه‌به معیارهای مهم و مختلف حوزه مطالعاتی مدل‌های پیش‌بینی ورشکستگی مشخص گردد. در کل می‌توان

نتیجه گرفت که هیچ ابزار واحدی وجود ندارد که اساساً بهتر از سایر ابزارها باتوجه‌به تمام معیارهای شناسایی شده باشد. با این حال مشخصاً هر ابزار نقاط قوت و ضعف خود را دارد که آن را برای وضعیت‌های خاصی (ویژگی‌های داده‌ها، هدف توسعه‌دهنده و...) مناسب‌تر می‌سازد. چهارچوب پیشنهادی مطالعه حاضر مشخصاً بستری فراهم ساخته که به انتخاب آگاهانه ابزارهایی که بهترین انطباق را با وضعیت توسعه‌دهنده مدل دارند کمک می‌کند.

پیامد مطالعه حاضر آن است که توسعه‌دهندگان مدل‌های پیش‌بینی ورشکستگی به‌جای انتخاب بر اساس محبوبیت و یا سایر عوامل غیرعلمی، اکنون می‌توانند تصمیمات آگاهانه‌ای را در راستای انتخاب ابزار برای مدل خود اتخاذ نمایند. در اصل، ابزارها مرتباً بر اساس نقاط قوت خود انتخاب می‌شوند. پیامد دیگر آن است که مدل‌های پیش‌بینی ورشکستگی با عملکرد بهتر باتوجه‌به نیاز کاربران نهایی، عموماً توسعه‌یافته‌تر خواهد بود. چهارچوب مطالعه حاضر باعث کاهش هدررفت زمان فرآیند توسعه مدل‌های پیش‌بینی ورشکستگی بسیاری با ابزارهای مختلف در راستای انتخاب بهترین گزینه پس از مجموعه آزمون‌ها می‌گردد؛ تنها ابزارهایی که بهترین انطباق را با وضعیت توسعه‌دهنده دارند مورد استفاده و مقایسه قرار خواهند گرفت. طبق یافته‌های پژوهش حاضر، شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان مناسب‌ترین ابزار بوده و برخی از معیارهای مدل‌های پیش‌بینی ورشکستگی را محقق می‌نمایند که این یافته، با نتایج پژوهش‌هایی همسو می‌باشد (*Mučko and Adamczyk*, 2023; *Alaka et al.*, 2016 and *Vlaović-Begović et al.*, 2022). اما پژوهش‌هایی نیز نشان داده‌اند که تکنیک‌های رگرسیون خطی و مدل باینری - لجستیک فالمر برای پیش‌بینی ورشکستگی مناسب‌تر هستند (*Wang and Liu*, 2021; *Lohmann et al.*, 2022 and *Ghamari*, 2022). (*Moghaddam et al.*, 2022).

مطالعات آینده باید احتمالات تفسیرپذیر سازی نتایج شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان را در نظر بگیرند؛ زیرا آن‌ها مناسب‌ترین ابزار بوده و برخی از معیارهای مدل‌های پیش‌بینی ورشکستگی را محقق می‌نمایند. بهترین مدل کلی که باتوجه‌به تمام و یا اکثر معیارها، از مدل‌های دیگر عملکرد بهتری دارد، اگرچه هنوز مشخص نشده، ممکن است به شکل ترکیبی از ابزارها باشد؛ بنابراین پژوهش‌های آتی باید از یک‌سو، ترکیب‌های مختلف را به‌منظور توسعه بهترین ترکیبی که می‌تواند به این انطباق دست یابد، بررسی نمایند. از سوی دیگر، مطالعات آتی باید استفاده از ابزارهای پیچیده‌تری مانند ماشین بارت، درخت‌های به‌شدت تصادفی و... را در نظر بگیرند. از آنجایی که ابزارهایی که می‌توانند با متغیرهای کیفی کار نمایند در این مطالعه ارائه شدند، مطالعات آتی باید گنجانند متغیرهای کیفی در توسعه مدل‌های پیش‌بینی ورشکستگی را که در بسیاری از مطالعات پیشنهاد شده لحاظ نمایند. در ضمن،

مطالعات آتی باید به ترکیب متغیرهای کمی و کیفی با استفاده از این ابزارها از دیدگاه توسعه مدل‌های پیش‌بینی ورشکستگی با عملکرد بهتر بپردازند. نهایتاً، پژوهش‌های آتی باید در پی تأیید و یا تکذیب قابلیت عالی ابزار ماشین‌های بردار پشتیبان در پیش‌بینی اندازه داده‌های کوچک باشند چرا که هر قدر داده‌ها بزرگ‌تر باشند بهتر است.

۶- تعارض منافع

هیچ‌گونه تعارض منافع در این پژوهش وجود ندارد.

۷- منابع

- Abellán, J., & Mantas, C. J. (2014). Improving experimental studies about ensembles of classifiers for bankruptcy prediction and credit scoring. *Expert Systems with Applications*, 41(8), 3825–3830.
- Ahmadpour Kasgari, A., Divsalar, M., Javid, M. R., & Ebrahimian, S. J. (2013). Prediction of bankruptcy Iranian corporations through artificial neural network and Probit-based analyses. *Neural Computing and Applications*, 23, 927–936.
- Alaka, H. A., Oyedele, L. O., Owolabi, H. A., Ajayi, S. O., Bilal, M., & Akinade, O. O. (2016). Methodological approach of construction business failure prediction studies: a review. *Construction Management and Economics*, 34(11), 808–842.
- Alibabae, G., & Khanmohammadi, M. (2022). The Study of the Predictive Power of Meta-heuristic Algorithms to Provide a Model for Bankruptcy prediction. *International Journal of Finance & Managerial Accounting*, 7(26), 33-51.
- Almaskati, N., Bird, R., Yeung, D., & Lu, Y. (2021). A horse race of models and estimation methods for predicting bankruptcy. *Advances in Accounting*, 52, 100513.
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589–609.
- Appiah, K. O., Chizema, A., & Arthur, J. (2015). Predicting corporate failure: a systematic literature review of methodological issues. *International Journal of Law and Management*, 57(5), 461–485.
- Arieshanti, I., Purwananto, Y., Ramadhani, A., Nuha, M. U., & Ulinuha, N. (2013). Comparative Study of Bankruptcy Prediction Models. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 11(3), 591-596.
- Beaver, W. H. (1966). Financial Ratios As Predictors of Failure. *Journal of Accounting Research*, 4(3), 71–111.
- Bemš, J., Starý, O., Macas, M., Žegklitz, J., & Petr Pošík. (2015). Innovative default prediction approach. *Expert Systems with Applications*, 42(17-18), 6277-6285.

- Boritz, J. E., & Kennedy, D. B. (1995). Effectiveness of neural network types for prediction of business failure. *Expert Systems with Applications*, 9(4), 503–512.
- Callejón, A. M., Casado, A. M., Fernández, M. A., & Peláez, J. I. (2013). A System of Insolvency Prediction for industrial companies using a financial alternative model with neural networks. *International Journal of Computational Intelligence Systems*, 6(1), 29–37.
- Chen, H.-L., Yang, B., Wang, G., Liu, J., Xu, X., Wang, S.-J., & Liu, D.-Y. (2011). A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest neighbor method. *Knowledge-Based Systems*, 24(8), 1348–1359.
- Chen, M.-Y. (2011). A hybrid model for business failure prediction -- Utilization of particle swarm optimization and support vector machines. *Neural Network World*, 21(2), 129–152.
- Chen, N., Ribeiro, B., Vieira, A. S., Duarte, J., & Neves, J. C. (2011). A genetic algorithm-based approach to cost-sensitive bankruptcy prediction. *Expert Systems with Applications*, 38(10), 12939–12945.
- Cho, S., Hong, H., & Ha, B.-C. (2010). A hybrid approach based on the combination of variable selection using decision trees and case-based reasoning using the Mahalanobis distance: For bankruptcy prediction. *Expert Systems with Applications*, 37(4), 3482–3488.
- Chuang, C.-L. (2013). Application of hybrid case-based reasoning for enhanced performance in bankruptcy prediction. *Information Sciences*, 236, 174–185.
- De Andrés, J., Landajo, M., & Lorca, P. (2012). Bankruptcy prediction models based on multinorm analysis: An alternative to accounting ratios. *Knowledge-Based Systems*, 30, 67–77.
- De Andrés, J., Lorca, P., de Cos Juez, F. J., & Sánchez-Lasheras, F. (2011). Bankruptcy forecasting: A hybrid approach using Fuzzy c-means clustering and Multivariate Adaptive Regression Splines (MARS). *Expert Systems with Applications*, 38(3), 1866–1875.
- Divsalar, M., Firouzabadi, A. K., Sadeghi, M., Behrooz, A. H., & Alavi, A. H. (2011). Towards the prediction of business failure via computational intelligence techniques. *Expert Systems*, 28(3), 209–226.
- Divsalar, M., Roodsaz, H., Vahdatinia, F., Norouzzadeh, G., & Behrooz, A. H. (2012). A Robust Data-Mining Approach to Bankruptcy Prediction. *Journal of Forecasting*, 31(6), 504–523.
- Dreiseitl, S., & Ohno-Machado, L. (2002). Logistic regression and artificial neural network classification models: a methodology review. *Journal of Biomedical Informatics*, 35(5-6), 352–359.
- Du Jardin, P. (2010). Predicting bankruptcy using neural networks and other classification methods: The influence of variable selection techniques on model accuracy. *Neurocomputing*, 73(10-12), 2047–2060.
- Du Jardin, P. (2015). Bankruptcy prediction using terminal failure processes. *European Journal of Operational Research*, 242(1), 286–303.

- Du Jardin, P., & Séverin, E. (2011). Predicting corporate bankruptcy using a self-organizing map: An empirical study to improve the forecasting horizon of a financial failure model. *Decision Support Systems*, 51(3), 701–711.
- Du Jardin, P., & Séverin, E. (2012). Forecasting financial failure using a Kohonen map: A comparative study to improve model stability over time. *European Journal of Operational Research*, 221(2), 378–396.
- Gepp, A., Kumar, K., & Bhattacharya, S. (2010). Business failure prediction using decision trees. *Journal of Forecasting*, 29(6), 536–555.
- Ghamari Moghaddam, A., Lari Dasht Bayaz, M., & Nakhaei, H. (2022). The relationship among the cash components of profit, the stability of profit and the probability of bankruptcy of companies listed in Tehran Stock Exchange. *Advances in Finance and Investment*, 3(8), 61-86. [In Persian]
- Gordini, N. (2014). A genetic algorithm approach for SMEs bankruptcy prediction: Empirical evidence from Italy. *Expert Systems with Applications*, 41(14), 6433–6445.
- Greco, S., Matarazzo, B., & Slowinski, R. (2001). Rough sets theory for multicriteria decision analysis. *European Journal of Operational Research*, 129(1), 1–47.
- Haghparsat, A., Momeni, A., Gord, A., & Mansoori, F. (2021). Imaged financial Ratios and Bankruptcy Prediction using Convolutional Neural Networks. *Financial Engineering and Portfolio Management*, 12(46), 558-575. [In Persian]
- Heidary, M., Ziari, S., Shayan Nia, S. A., & Rashidi Kemijan, A. (2021). Financial Bankruptcy prediction using artificial neural network and firefly algorithms in companies listed in Tehran Stock Exchange. *Financial Engineering and Portfolio Management*, 12(46), 691-716. [In Persian]
- Heo, J., & Yang, J. Y. (2014). AdaBoost based bankruptcy forecasting of Korean construction companies. *Applied Soft Computing*, 24, 494–499.
- Ho, C.-Y., McCarthy, P., Yang, Y., & Ye, X. (2012). Bankruptcy in the pulp and paper industry: market's reaction and prediction. *Empirical Economics*, 45(3), 1205–1232.
- Huang, S.-C., Tang, Y.-C., Lee, C.-W., & Chang, M.-J. (2012). Kernel local Fisher discriminant analysis based manifold-regularized SVM model for financial distress predictions. *Expert Systems with Applications*, 39(3), 3855–3861.
- Jackson, R. H. G., & Wood, A. (2013). The performance of insolvency prediction and credit risk models in the UK: A comparative study. *The British Accounting Review*, 45(3), 183–202.
- Jeong, C., Min, J. H., & Kim, M. S. (2012). A tuning method for the architecture of neural network models incorporating GAM and GA as applied to bankruptcy prediction. *Expert Systems with Applications*, 39(3), 3650–3658.

- Karpoff, J. M., Koester, A., Lee, D. S., & Martin, G. S. (2017). Proxies and Databases in Financial Misconduct Research. *The Accounting Review*, 92(6), 129–163.
- Khademolqorani, S., Zeinal Hamadani, A., & Mokhatab Rafiei, F. (2015). A Hybrid Analysis Approach to Improve Financial Distress Forecasting: Empirical Evidence from Iran. *Mathematical Problems in Engineering*, 2015, 1–9.
- Kim, M.-J., & Kang, D.-K. (2010). Ensemble with neural networks for bankruptcy prediction. *Expert Systems with Applications*, 37(4), 3373–3379.
- Kim, S. Y. (2011). Prediction of hotel bankruptcy using support vector machine, artificial neural network, logistic regression, and multivariate discriminant analysis. *The Service Industries Journal*, 31(3), 441–468.
- Kristóf, T., & Virág, M. (2012). Data reduction and univariate splitting — Do they together provide better corporate bankruptcy prediction? *Acta Oeconomica*, 62(2), 205–228.
- Lee, S., & Choi, W. S. (2013). A multi-industry bankruptcy prediction model using back-propagation neural network and multivariate discriminant analysis. *Expert Systems with Applications*, 40(8), 2941–2946.
- Li, H., Lee, Y.-C., Zhou, Y.-C., & Sun, J. (2011). The random subspace binary logit (RSBL) model for bankruptcy prediction. *Knowledge-Based Systems*, 24(8), 1380–1388.
- Liang, D., Tsai, C.-F., & Wu, H.-T. (2015). The effect of feature selection on financial distress prediction. *Knowledge-Based Systems*, 73, 289–297.
- Lin, F., Liang, D., & Wing Sang Chu. (2010). The role of non-financial features related to corporate governance in business crisis prediction. *Journal of Marine Science and Technology*, 18(4), 504-513.
- Lohmann, C., Möllenhoff, S., & Ohliger, T. (2022). Nonlinear relationships in bankruptcy prediction and their effect on the profitability of bankruptcy prediction models. *Journal of Business Economics*, 93, 1661-1690.
- López Iturriaga, F. J., & Sanz, I. P. (2015). Bankruptcy visualization and prediction using neural networks: A study of U.S. commercial banks. *Expert Systems with Applications*, 42(6), 2857–2869.
- Mućko, P., & Adamczyk, A. (2023). Does the bankrupt cheat? Impact of accounting manipulations on the effectiveness of a bankruptcy prediction. *PLOS ONE*, 18(1), 1-13.
- Odom, M. D., & Sharda, R. (1990). A neural network model for bankruptcy prediction. *1990 IJCNN International Joint Conference on Neural Networks*.
- Olson, J. A., Schmidt, P., & Waldman, D. M. (1980). A Monte Carlo study of estimators of stochastic frontier production functions. *Journal of Econometrics*, 13(1), 67–82.
- Pawełek, B. (2019). Extreme gradient boosting method in the prediction of company bankruptcy. *Statistics in Transition. New Series*, 20(2), 155–171.

- Pawlak, Z. (1982). Rough sets. *International Journal of Computer & Information Sciences*, 11(5), 341–356.
- Pourgadimi, K., Bahri Sales, J., Jabbarzadeh Kangarluei, S., & Zavar Rezaee, A. (2022). Presenting the developed model of benish model with emphasis on audit quality features using neural network, vector machine and random forest. *Advances in Finance and Investment*, 3(6), 1-30. [In Persian]
- Ravi Kumar, P., & Ravi, V. (2007). Bankruptcy prediction in banks and firms via statistical and intelligent techniques – A review. *European Journal of Operational Research*, 180(1), 1–28.
- Saroei, S., Vkili Fard., H. R., & Taleb Nia, G. (2022). Comparison of the Predictive Accuracy of Artificial Neural Network Systems Based on Multilayer Perceptron Approach and Falmer Binary-Logistics Model in Order to Predict Bankruptcy. *Financial Engineering and Portfolio Management*, 13(52), 102-120. [In Persian]
- Shie, F. S., Chen, M.-Y., & Liu, Y.-S. (2012). Prediction of corporate financial distress: an application of the America banking industry. *Neural Computing and Applications*, 21(7), 1687–1696.
- Shin, K.-S., Lee, T. S., & Kim, H. (2005). An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28(1), 127–135.
- Tam, K. Y., & Kiang, M. Y. (1992). Managerial Applications of Neural Networks: The Case of Bank Failure Predictions. *Management Science*, 38(7), 926–947.
- Tsai, C.-F. (2014). Combining cluster analysis with classifier ensembles to predict financial distress. *Information Fusion*, 16, 46–58.
- Tsai, C.-F., & Cheng, K.-C. (2012). Simple instance selection for bankruptcy prediction. *Knowledge-Based Systems*, 27, 333–342.
- Tsai, C.-F., & Hsu, Y.-F. (2013). A Meta-learning Framework for Bankruptcy Prediction. *Journal of Forecasting*, 32(2), 167–179.
- Tsai, C.-F., Hsu, Y.-F., & Yen, D. C. (2014). A comparative study of classifier ensembles for bankruptcy prediction. *Applied Soft Computing*, 24, 977–984.
- Tseng, F.-M., & Hu, Y.-C. (2010). Comparing four bankruptcy prediction models: Logit, quadratic interval logit, neural and fuzzy neural networks. *Expert Systems with Applications*, 37(3), 1846–1853.
- Tserng, H. P., Chen, P.-C., Huang, W.-H., Lei, M. C., & Tran, Q. H. (2014). Prediction of default probability for construction firms using the logit model. *Journal of Civil Engineering and Management*, 20(2), 247–255.
- Virág, M., & Nyitrai, T. (2014). Is there a trade-off between the predictive power and the interpretability of bankruptcy models? The case of the first Hungarian bankruptcy prediction model. *Acta Oeconomica*, 64(4), 419–440.
- Vlaović-Begović, S., Tomašević, S., & Ercegovac, D. (2022). Selection of variables in the function of improving the bankruptcy prediction model. *Ekonomika*, 68(3), 45–59.

- Wang, G., Ma, J., & Yang, S. (2014). An improved boosting based on feature selection for corporate bankruptcy prediction. *Expert Systems with Applications*, 41(5), 2353–2361.
- Wang, H., & Liu, X. (2021). Undersampling bankruptcy prediction: Taiwan bankruptcy data. *PLOS ONE*, 16(7), 1-17.
- Wilson, R. L., & Sharda, R. (1994). Bankruptcy prediction using neural networks. *Decision Support Systems*, 11(5), 545–557.
- Xiong, T., Wang, S., Mayers, A., & Monga, E. (2013). Personal bankruptcy prediction by mining credit card data. *Expert Systems with Applications*, 40(2), 665–676.
- Yang, Z., You, W., & Ji, G. (2011). Using partial least squares and support vector machines for bankruptcy prediction. *Expert Systems with Applications*, 38(7), 8336–8342.
- Yeh, C.-C., Chi, D.-J., & Lin, Y.-R. (2014). Going-concern prediction using hybrid random forests and rough set approach. *Information Sciences*, 254, 98–110.
- Yoon, J. S., & Kwon, Y. S. (2010). A practical approach to bankruptcy prediction for small businesses: Substituting the unavailable financial data for credit card sales information. *Expert Systems with Applications*, 37(5), 3624–3629.
- Yu, Q., Miche, Y., Séverin, E., & Lendasse, A. (2014). Bankruptcy prediction using Extreme Learning Machine and financial expertise. *Neurocomputing*, 128, 296–302.
- Zambrano Farias, F., Valls Martínez, M. del C., & Martín-Cervantes, P. A. (2021). Explanatory Factors of Business Failure: Literature Review and Global Trends. *Sustainability*, 13(18), 10154-10178.
- Zhou, L., Lai, K. K., & Yen, J. (2012). Bankruptcy prediction using SVM models with a new approach to combine features selection and parameter optimisation. *International Journal of Systems Science*, 45(3), 241–253.
- Zhou, L., Lai, K. K., & Yen, J. (2012). Empirical models based on features ranking techniques for corporate financial distress prediction. *Computers & Mathematics with Applications*, 64(8), 2484–2496.

COPYRIGHTS

© 2023 by the authors. Published by Islamic Azad University, Esfaryan Branch. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) (<http://creativecommons.org/licenses/by/4.0/>).

