



Grey Wolf Optimization Evolving Kernel Extreme Learning Machine: Application to Bankruptcy Prediction

Tohid Golizadeh Salteh

*Corresponding author, MSc. Student, Department of Finance, Faculty of Financial Sciences, University of Kharazmi, Tehran, Iran. E-mail: gholizadeh1991@gmail.com

Mohammad Eghbalnia

Assistant Prof., Department of Finance, Faculty of Financial Sciences, University of Kharazmi, Tehran, Iran. E-mail: meghbalnia@khu.ac.ir

Mohammad Ebrahim Aghababaei

Assistant Prof., Department of Financial Engineering and Financial Management, Faculty of Financial Sciences, University of Kharazmi, Tehran, Iran. E-mail: m.aghababaei@khu.ac.ir

Abstract

Objective: In the present era, businesses have developed to a large extent which has, in turn, forced them to manage their resources and expenditures wisely for the sake of competition. This is mainly because the competitive market has severely reduced the flexibility of companies, which means that their ability respond to different economic situations has reduced and this puts most firms at the constant risk of bankruptcy and contraction. Therefore, in this study, we have tried to predict the bankruptcy of manufacturing companies through preventing the occurrence of such risks.

Methods: In this study, the "Kernel Extreme Learning Machine" has been used as one of the artificial intelligence models for predicting bankruptcy. Given that machine learning methods require an optimization algorithm we have used one of the most up-to-date, "Gray Wolf Algorithm" which has been introduced in 2014.

Results: The above model has been implemented on the 136 samples that were collected from the Tehran Stock Exchange between 2015 and 2018. All of the performance evaluation criteria including the classification, accuracy, type error, second-order error and area under the ROC curve showed better performance than the genetic algorithm which was presented and its significance was confirmed by t-test.

Conclusion: Considering the gray wolf algorithm's high accuracy and its performance compared to the genetic algorithm, it is necessary to use the gray wolf algorithm to predict the bankruptcy of Iranian manufacturing companies either for investment purposes and for validation purposes, or for using internal management of the company.

Keywords: Bankruptcy prediction, Learning machine, Grey Wolf Optimizer (GWO), Financial ratios.

Citation: Golizadeh Salteh, T., Eghbalnia, M., & Aghababaei, M.E. (2019). Grey Wolf Optimization Evolving Kernel Extreme Learning Machine: Application to Bankruptcy Prediction. *Financial Research Journal*, 21(2), 187- 212. (in Persian)

Financial Research Journal, 2019, Vol. 21, No.2, pp. 187- 212

DOI: 10.22059/frj.2019.277620.1006839

Received: December 09, 2018; Accepted: April 22, 2019

© Faculty of Management, University of Tehran



پیش‌بینی ورشکستگی با مدل یادگیری ماشین سریع مبتنی بر کرنل بهینه‌شده با الگوریتم گرگ خاکستری

توحید قلی‌زاده سالطه

* نویسنده مسئول، دانشجوی کارشناسی ارشد، گروه مدیریت مالی، دانشکده علوم مالی، دانشگاه خوارزمی، تهران، ایران. رایانامه: gholizadeh1991@gmail.com

محمد اقبال‌نیا

استادیار، گروه آموزشی مدیریت مالی، دانشکده علوم مالی، دانشگاه خوارزمی، تهران، ایران. رایانامه: meghbaltia@khu.ac.ir

محمد ابراهیم آقابابائی

استادیار، گروه آموزشی مهندسی مالی و مدیریت مالی، دانشکده علوم مالی، دانشگاه خوارزمی، تهران، ایران. رایانامه: m.aghbabaei@khu.ac.ir

چکیده

هدف: در عصر حاضر، کسب‌وکارها به اندازه‌ای توسعه یافته‌اند که برای بقا در عرصه رقابت، به مدیریت صحیح منابع و مصارف خود نیازمندند؛ چراکه بازار رقابتی انعطاف‌پذیری شرکت‌ها را به شدت کاهش داده است و این عامل باعث شده که آنها در وضعیت‌های مختلف اقتصادی توانایی عکس‌العمل مناسب را نداشته باشند و از چرخه رقابت خارج شده و با خطر ورشکستگی مواجه شوند. بنابراین در این پژوهش تلاش شده است که به منظور پیشگیری از احتمال بروز چنین مخاطراتی، به پیش‌بینی ورشکستگی شرکت‌های تولیدی اقدام کنیم.

روش: در این پژوهش از «یادگیری ماشین سریع مبتنی بر کرنل» استفاده شده که یکی از مدل‌های هوش مصنوعی برای پیش‌بینی ورشکستگی است. با توجه به اینکه روش‌های یادگیری ماشین به الگوریتمی بهینه‌ساز نیاز دارند، در این پژوهش از یکی از به‌روزترین آنها به نام «الگوریتم گرگ خاکستری» بهره برده شده که در سال ۲۰۱۴ ابداع شده است.

یافته‌ها: مدل یاد شده روی داده‌های ۱۳۶ نمونه از شرکت‌های بورسی در بازه زمانی ۱۳۹۴ تا پایان خرداد ۱۳۹۷، پیاده‌سازی شد و در تمامی معیارهای ارزیابی، مدل‌های طبقه‌بندی، دقت، خطاهای نوع اول و دوم و ناحیه تحت منحنی ROC، در مقایسه با الگوریتم ژنتیک، کارایی بهتری ارائه کرد و معناداری آن نیز از طریق آزمون t-test به تأیید رسید.

نتیجه‌گیری: با توجه به دقت بسیار خوب الگوریتم گرگ خاکستری و همچنین عملکرد بهتر آن در مقایسه با الگوریتم ژنتیک، می‌بایست برای پیش‌بینی ورشکستگی شرکت‌های تولیدی ایران، چه برای اهداف سرمایه‌گذاری و اعتباردهی و چه به منظور استفاده مدیریت داخلی شرکت، از الگوریتم گرگ خاکستری بهره برد.

کلیدواژه‌ها: پیش‌بینی ورشکستگی، یادگیری ماشین، بهینه‌سازی گرگ خاکستری، نسبت‌های مالی.

استناد: قلی‌زاده، سالطه، توحید؛ اقبال‌نیا، محمد؛ آقابابائی، محمد ابراهیم (۱۳۹۸). پیش‌بینی ورشکستگی با مدل یادگیری ماشین سریع مبتنی بر کرنل بهینه‌شده با الگوریتم گرگ خاکستری. *تحقیقات مالی*، ۲۱(۲)، ۱۸۷-۲۱۲.

تحقیقات مالی، ۱۳۹۸، دوره ۲۱، شماره ۲، صص. ۱۸۷-۲۱۲

DOI: 10.22059/ftj.2019.277620.1006839

دریافت: ۱۳۹۷/۰۹/۱۸، پذیرش: ۱۳۹۸/۰۲/۰۲

© دانشکده مدیریت دانشگاه تهران

مقدمه

با توجه به افزایش سهم بخش صنعت در رشد اقتصادی کشورهای در حال توسعه و پررنگ‌تر شدن نقش صنعت در توانمندی اقتصادی کشورها، نیاز به توجه بیشتر و مراقبه از زیر بخش‌های صنعتی، اهمیت شایان توجهی پیدا می‌کند. روان‌سازی مسیر رو به رشد و به بلوغ رسیدن شرکت‌های تولیدی، از اقدامات مهم در جهت پویایی بخش صنعت است. با توجه به اینکه مؤلفه‌های مالی و جریان‌های نقدی هر شرکتی همانند خون در رگ انسان عمل می‌کنند، پیشگیری قبل از وقوع بحران‌های مالی و رفع موانع از مسیر رو به رشد شرکت‌ها، می‌تواند هدف ما را محقق سازد. عواقب ورشکستگی شرکت‌ها نه تنها بحران مالی در خود شرکت را باعث می‌شود، بلکه ذی‌نفعان را متضرر می‌سازد و در نهایت رشد اقتصادی جامعه را با مشکل مواجه می‌کند. به‌منظور پیشگیری از چنین عواقبی، توانایی پیش‌بینی ورشکستگی شرکت، مهم و حیاتی به‌شمار می‌رود. بیور^۱ در سال ۱۹۶۶ چند نشانه از شرکت‌های ورشکسته را همانند نکول اوراق منتشر شده، مازاد برداشت از حساب بانکی، عدم تقسیم سود نقدی، افزایش زیان انباشته به بیش از نیمی از سرمایه ثبتي و تسویه شرکت برشمرده است. تحقیقات بسیاری در خصوص ویژگی شرکت‌های ورشکسته انجام شده است و هر یک تلاش کرده‌اند که از زاویه خاصی به این موضوع بپردازند و ورشکستگی شرکت‌ها را پیش از رخداد، پیش‌بینی کنند. معیار تشخیص ورشکستگی شرکت‌ها در این تحقیق، ماده ۱۴۱ قانون تجارت ایران^۲ (بر اثر زیان‌های وارده، حداقل نصف سرمایه شرکت از بین برود) در نظر گرفته شده است.

بنابراین تبیین مدلی که بتواند ورشکستگی شرکت را زودتر از رخداد پیش‌بینی کند، به شرکت در این خصوص هشدارهای لازم را می‌دهد و از طرفی به مؤسسه‌های مالی نیز برای سنجش توان بازپرداخت تسهیلات ارائه شده به شرکت‌های در معرض ورشکستگی، کمک شایانی می‌کند. با توجه به تنگنای مالی و وضعیت نابسامان نقدینگی که مؤسسه‌های مالی در این برهه زمانی با آن مواجه‌اند، برای ارائه تسهیلات باید حساسیت زیادی در این زمینه نشان دهند. تاکنون، برای پیش‌بینی ورشکستگی مدل‌های طبقه‌بندی متعددی بر اساس دانش در زمینه‌های مختلف پیشنهاد شده است. به‌طور کلی، مدل‌های پیشنهاد شده را می‌توان به دو دسته رویکردهای آماری و روش‌های هوش مصنوعی^۳ طبقه‌بندی کرد. استفاده از نسبت‌های مالی و طبقه‌بندی به دو گروه ورشکسته و غیرورشکسته، دو شالوده اصلی روش‌های نام‌برده است.

در این تحقیق با اشاره به نتایج پذیرفته شده روش‌های هوش مصنوعی در مقایسه با رویکردهای آماری، سعی بر آن است که با به‌کارگیری نسبت‌های مالی به‌دست آمده از صورت‌های مالی شرکت‌ها، ورشکستگی را به‌کمک مدل GWO-EELM^۴ پیش‌بینی کرده و خطای پیش‌بینی را با مدل GA-KELM مقایسه کنیم.

1. Beaver

۲. قانون تجارت، مصوب ۱۳ اردیبهشت ماه ۱۳۱۱، کمیسیون قوانین عدلیه

3. Artificial Intelligence (AI)

4. Grey Wolf Optimization-Kernel Extreme Learning Machine

ورشکستگی

در فرهنگ لغات آکسفورد، واژه «Bankruptcy» به معنای ورشکستگی، افلاس و توقف بازرگان آورده شده است. در ادبیات مالی نیز تعاریف مختلفی از ورشکستگی ارائه شده است که در ادامه به چند نمونه از آنها اشاره می‌شود. ورشکستگی در لغت به معنای درماندگی در کسب و تجارت است و به وضعیت بازرگانی اطلاق می‌شود که در تجارت زیان دیده است، بدهی او بیش از دارایی‌اش بوده و از پرداخت بدهی‌های خود ناتوان است و به همین دلیل نمی‌تواند به تعهدهای تجاری خود عمل کند. در ماده ۴۱۲ قانون تجارت، ورشکستگی این گونه تعریف شده است که ورشکستگی در نتیجه توقف از تأدیه وجوهی که بر عهده تاجر است، رخ می‌دهد؛ یعنی به محض اینکه تاجر یا شرکت تجاری قادر نباشد دیون خود را پرداخت کند، ورشکسته می‌شود (قانون تجارت، ۱۳۱۱). همچنین مطابق نظر گیتمان و پاراناس^۱ (۱۹۹۶)، ورشکستگی به حالتی اطلاق می‌شود که بدهی‌های شرکت از ارزش بازار دارایی‌های موجود در شرکت تجاوز کند. از نظر شاکری (۱۳۸۲)، هرگاه میزان بازده شرکتی منفی و شرکت در پرداخت بدهی‌های خود ناتوان باشد، شرکت ورشکسته نامیده می‌شود.

پیشینه پژوهش

به‌طور کلی، مدل‌های پیشنهاد شده برای پیش‌بینی ورشکستگی را می‌توان به دو دسته رویکردهای آماری یا روش‌های هوش مصنوعی طبقه‌بندی کرد. رویکردهای آماری معمولی که برای مدل پیش‌بینی ورشکستگی ساخته می‌شوند، تجزیه و تحلیل تک‌متغیره ساده^۲ (بیور، ۱۹۶۶)، تجزیه و تحلیل چندمتغیره (آلتمن^۳، ۱۹۶۸)، رگرسیون لجستیک (آلسون^۴، ۱۹۸۰) و تحلیل عاملی (وست^۵، ۱۹۸۵) را انجام می‌دهند. در سال‌های اخیر، روش‌های هوش مصنوعی بیشتر برای پیش‌بینی ورشکستگی تلاش می‌کنند. روش‌های مبتنی بر هوش مصنوعی، مانند شبکه‌های عصبی مصنوعی^۶ (آتیا^۷، ۲۰۰۱)، پشتیبانی از ماشین‌های بردار (مین و لی^۸، ۲۰۰۵؛ شین، لی و کیم^۹، ۲۰۰۵)، نزدیک‌ترین معیار (چن و همکاران^{۱۰}، ۲۰۱۱)، مدل شبکه‌های بیزی (سرکار و اِسیریم^{۱۱}، ۲۰۰۱)، دستگاه یادگیری سریع و روش‌های گروه (فدوروا، گیلنکو و دُوچنکو^{۱۲}، ۲۰۱۳)، به‌عنوان روش‌های مختلف هیبرید، به‌طور گسترده و خوبی در حوزه مالی استفاده می‌شوند که در ادامه به نمونه‌هایی از آنها به ترتیب سال انتشار اشاره شده است.

شاه و مرتزا^{۱۳} در سال ۲۰۰۰ مدلی را با استفاده از شبکه عصبی مصنوعی برای پیش‌بینی ورشکستگی ارائه دادند. در این مطالعه از اطلاعات ۶۰ شرکت ورشکسته و ۵۴ شرکت غیرورشکسته بین سال‌های ۱۹۹۲ تا ۱۹۹۴ استفاده شده است. دقت پیش‌بینی این مدل ۷۳ درصد بود.

1. Gitman & Parnas
3. Altman
5. West
7. Atiya
9. Shin, Lee, & Kim
11. Sarkar and Sriram
13. Shah & Murtaza

2. Simple Univariate Analysis
4. Ohlson
6. Artificial Neural Network (ANN)
8. Min and Lee
10. Chen & et al
12. Fedorova, Gilenko, & Dovzhenko

راوی و پرامود^۱ در سال ۲۰۰۸ مدل جدیدی را به نام شبکه عصبی مؤلفه اصلی^۲ پیشنهاد دادند که برای پیش‌بینی مشکل ورشکستگی در بانک‌های تجاری استفاده شود. نتیجه پژوهش برتری هیبریدهای پیشنهادی شبکه عصبی مؤلفه اصلی را در مقایسه با طبقه‌بندی‌های دیگر مجموعه داده‌های ورشکستگی نشان داد.

پارامجیت و راوی^۳ در سال ۲۰۱۱ به منظور پیش‌بینی ورشکستگی در بانک‌ها، روش اصلاح باکتری را برای آموزش شبکه عصبی موجکی پیشنهاد دادند. واسو و راوی^۴ در سال ۲۰۱۱ برای پیش‌بینی ورشکستگی در بانک‌ها، مدل تجزیه و تحلیل مؤلفه اصلی هیبرید شبکه عصبی موجک^۵ پیشنهاد شده توسط الگوریتم پذیرش حد آستانه را ارائه دادند. نتایج تجربی نشان داد که تجزیه و تحلیل مؤلفه اصلی هیبرید شبکه عصبی موجک می‌تواند روش‌های دیگر را از لحاظ منطقه تحت منحنی^۶ مشخصه عملکرد سیستم^۷ در ۱۰ طبقه اعتبارسنجی متقابل بررسی کند. ردی و راوی^۸ در سال ۲۰۱۳ دو روش محاسباتی نرم‌افزاری را برای انجام وظیفه طبقه‌بندی بر اساس دو کرنل جدید (novel kernels) پیشنهاد کردند. نتایج تجربی نشان داد که رویکرد پیشنهادی می‌تواند برای پیش‌بینی ورشکستگی مناسب باشد. شارما^۹ و همکارانش در سال ۲۰۱۳ نوعی الگوریتم هیبریدی مبتنی بر بهینه‌سازی مورچه‌ها و سیمپلکس نلدر - میلد^{۱۰} را برای آموزش شبکه‌های عصبی به منظور استفاده در پیش‌بینی ورشکستگی ارائه کردند.

در تمام روش‌های کار شده (زانگ، میخائل، پتو و دنیل^{۱۱}، ۱۹۹۹؛ آتیا، ۲۰۰۱؛ تسای و وو^{۱۲}، ۲۰۰۸)، شبکه‌های عصبی مصنوعی به دلیل توانایی برجسته در یافتن رابطه غیرخطی موجود میان ویژگی‌های مختلف در مجموعه داده‌های واقعی، برای پیش‌بینی‌های مالی محبوب‌تر بودند. با وجود این، باید اضافه کرد که روش‌های یادگیری شبکه‌های عصبی مصنوعی مانند روش پس انتشار^{۱۳}، بر استراتژی نزول گرادینان^{۱۴} مبتنی است که گاهی به بهینه‌سازی محلی منجر می‌شود، ضمن آنکه به طور کلی باید مقدار مناسبی از پارامترهای شبکه تنظیم شود. به منظور جلوگیری از کاستی‌های شبکه‌های عصبی مصنوعی، هوانگ، ژو و سیو^{۱۵} در سال ۲۰۰۶ پارادایم یادگیری ماشینی را به نام ماشین یادگیری سریع پیشنهاد دادند. ماشین یادگیری سریع نوعی مدل یادگیرنده نمایشی شبکه عصبی محسوب می‌شود که به دنبال شبکه‌های عصبی پیشخور تک‌لایه پنهان است. تورش‌های پنهان و وزن‌های ورودی در این روش به صورت تصادفی تولید می‌شود و وزن خروجی به صورت ریاضی با استفاده از معادله مور-پنروس^{۱۶} به دست می‌آید.

به خوبی روشن شده است که تقریب جهانی، قابلیت تقریبی شبکه‌های عصبی را بازتاب می‌دهد. هورنیک^{۱۷} در سال ۱۹۹۱ توانایی تخمین شبکه‌های پیشنهادی چندلایه را نشان داد؛ یعنی، توابع فعال پیوسته ثابت بدون محدودیت و

- | | |
|---|--|
| 1. Ravi & Pramodh | 2. Principal Component Neural Network (PCNN) |
| 3. Paramjeet & Ravi | 4. Vasu & Ravi |
| 5. Principal Component Analysis-Wavelet Neural Network hybrid (PCATAWNN) | |
| 6. Area Under the Curve (AUC) | |
| 7. Receiver Operating Characteristic (ROC) | 8. Reddy & Ravi |
| 9. Sharma | |
| 10. A hybrid algorithm based on ant colony optimization and Nelder-Mead simplex | |
| 11. Zhang, Michael, Patuwo & Daniel | 12. Tsai and Wu |
| 13. Back-propagation approach | 14. Gradient descent strategy |
| 15. Huang, Zhu & Siew | 16. Moore-Penrose (MP) |
| 17. Hornik | |

نگاشت‌های پیوسته را می‌توان در شبکه‌های عصبی اندازه‌گیری کرد. لشنو، لین، پینکوس و اسچوکن^۱ در سال ۱۹۹۳ نشان دادند که توابع پیوسته به کمک شبکه‌های پیش‌فرض با یک تابع فعال غیرچندجمله‌ای برآورد می‌شوند. گوانگ بین و بابری^۲ در سال ۱۹۹۸ نشان دادند که شبکه‌های عصبی پیشخور تک‌لایه پنهان با گره‌های پنهان N و تابع فعال‌سازی تقریباً غیرخطی، می‌توانند مشاهدات متمایز N را به‌طور دقیق یاد بگیرند. با توجه به عملکرد طبقه‌بندی آن، مدل یادگیری ماشین سریع در زمینه‌هایی نظیر طبقه‌بندی، تشخیص بیماری‌ها و برنامه مهندسی پذیرفته شده است. علاوه‌بر این، روش‌های مبتنی بر مدل یادگیری ماشین سریع نیز به‌طور گسترده‌ای در زمینه‌های مالی مانند پیش‌بینی ورشکستگی، پیش‌بینی‌های چرخه عمر شرکت و رتبه‌بندی اعتبار شرکت‌ها استفاده می‌شود. با وجود این، یکی از محدودیت‌های مدل یادگیری ماشین سریع این است که وزن‌های ورودی به‌طور تصادفی تعیین می‌شود که احتمال دارد تغییرات دقیق ایجاد شده از طبقه‌بندی‌ها را در آزمایش‌های مختلف افزایش دهد. به‌منظور غلبه بر این محدودیت، هوانگ و همکارانش در سال ۲۰۱۲ ماشین یادگیری سریع مبتنی بر کرنل (KELM) را پیشنهاد کردند که وزن اتصال آن بین لایه‌های پنهان و ورودی ضروری نیست. در مقایسه با مدل یادگیری ماشین سریع، KELM می‌تواند امکانات نسبی عالی‌تری را با سرعت آموزش سریع‌تر و اجرای بسیار ساده‌تر در برنامه‌های کاربردی ارائه دهد.

زائو و همکارانش^۳ (۲۰۱۷)، KELM را برای حل مسئله پیش‌بینی ورشکستگی معرفی کردند و در مقایسه با پنج روش دیگر در این زمینه، از جمله ماشین بردار پشتیبان^۴، مدل یادگیری ماشین سریع، جنگل تصادفی^۵، مدل KNN فازی بهینه‌سازی شده با الگوریتم ازدحام ذرات^۶ و مدل لاجیت^۷، در همان مجموعه داده‌های واقعی به عملکردی بهتری دست یافتند.

سعیدی و آقایی در سال ۱۳۸۸ در پژوهشی با استفاده از شبکه‌های بیز به پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداختند. در این پژوهش دو مدل با استفاده از شبکه‌های بیز و یک مدل با استفاده از رگرسیون لاجیت برای نمونه انتخاب شد. نخستین مدل شبکه ساده بیز که بر همبستگی شرطی مبتنی بود، توانست با دقت ۹۰ درصد شرکت‌های ورشکسته و غیرورشکسته را درست پیش‌بینی کند. دومین مدل شبکه ساده بیز که بر احتمال شرطی مبتنی بود، با دقت ۹۳ درصد و مدل رگرسیون لجستیک با دقت ۹۰ درصد شرکت‌های ورشکسته و غیرورشکسته را درست پیش‌بینی کردند.

خورشیدی (۱۳۹۵) با استفاده از مدل هشدار سریع مالی لاجیت، ورشکستگی مالی شرکت‌های دو صنعت خودرو - قطعات و ماشین‌آلات - تجهیزات را در بورس اوراق بهادار تهران پیش‌بینی کرد و برای بررسی کارایی آن از شیوه تحلیل پوششی داده‌ها بهره برد. متغیرهای مستقل این پژوهش بیست نسبت مالی بود و متغیرهای وابسته دو گروه شرکت‌های با رفتار خاص و دارای سود خالص منفی در دو سال متوالی و شرکت‌های سالم بدون سود خالص منفی در دو سال متوالی

1. Leshno, Lin, Pinkus & Schocken

2. Guang-Bin and Babri

3. Zhao & et al

4. Support vector machine (SVM)

5. Random Forest (RF)

6. Fuzzy k-Nearest Neighbor Method Based on Parallel Particle Swarm Optimization

7. Logit

در نظر گرفته شدند. بر اساس مدل لاجیت، دو نسبت بازده دارایی‌ها و نسبت بدهی، نسبت‌های مؤثر بر ورشکستگی مالی شرکت‌ها در این تحقیق شناسایی شدند. میزان کلی پیش‌بینی دقت مدل در آزمون درون نمونه‌ای، ۷۹/۵ درصد و در آزمون خارج از نمونه، ۸۷/۱ درصد به دست آمد.

فلاح‌پور و ارم (۱۳۹۵) به پیش‌بینی درماندگی مالی شرکت‌ها با استفاده از الگوریتم کلونی مورچگان اقدام کردند. جامعه آماری تحقیق، شرکت‌های بورس اوراق بهادار تهران بود و نمونه پژوهش ۱۷۴ شرکت درمانده و سالم را در بر می‌گرفت. متغیرهای پیش‌بین بر اساس نسبت‌هایی انتخاب شدند که در نتایج تحقیقات قبلی متغیرهای اصلی پیش‌بینی در مدل پیش‌بینی بودند. مدل مقایسه‌ای استفاده‌شده در این پژوهش، مدل تحلیل ممیز چندگانه بود. نتایج به‌دست‌آمده از تحقیق بیان‌کننده آن است که روش الگوریتم کلونی مورچگان در پیش‌بینی درماندگی مالی شرکت‌ها، به‌طور معناداری نسبت به روش تحلیل ممیز چندگانه عملکرد بهتری دارد.

فلاح‌پور، نوروزی‌یان لکوان و هندیجانی زاده (۱۳۹۶) با استفاده از ماشین بردار پشتیبان با چهار تابع کرنل خطی، چندجمله‌ای، شعاعی و سیگموئید به‌عنوان مدل طبقه‌بندی‌کننده و ترکیب آن با روش‌های انتخاب ویژگی فیلترکننده و پوشش‌دهنده، به پیش‌بینی درماندگی مالی اقدام کردند. نتایج به‌دست‌آمده نشان داد که روش الگوریتم ژنتیک نسبت به روش‌های فیلترکننده، عملکرد بهتری دارد. همچنین دقت ماشین بردار پشتیبان با توابع کرنل خطی، چندجمله‌ای، شعاعی و سیگموئید در ترکیب با الگوریتم ژنتیک، در سطح اطمینان ۹۵ درصد تفاوت معناداری با هم ندارند.

فلاح‌پور، راعی و نوروزی‌یان (۱۳۹۷) در تحقیق دیگری، با استفاده از روش‌های انتخاب ویژگی پی‌درپی پیش‌رو شناور که مدل تعمیم‌یافته روش انتخاب ویژگی پیش‌رو پی‌درپی و از دسته روش‌های پوشش‌دهنده است و روش انتخاب ویژگی پیش‌رو پی‌درپی در ترکیب با ماشین بردار پشتیبان، درماندگی مالی شرکت‌ها را پیش‌بینی کردند. پس از بررسی نسبت‌های مالی مهم، در نهایت ۲۹ نسبت مالی که در تحقیقات گذشته بیشتر استفاده شده بودند، انتخاب شدند. آزمون مقایسه‌های زوجی نشان داد که دقت مدل پیشنهادی این پژوهش با سطح اطمینان ۹۵ درصد، بهتر از سایر مدل‌های استفاده شده در این پژوهش است.

بت‌شکن، سلیمی و فلاح‌تگر (۱۳۹۷) با رویکردی جدید برای انتخاب متغیرهای مؤثر و با استفاده از نظر خبرگان و الگوریتم‌های تصمیم‌گیری، به پیش‌بینی درماندگی مالی اقدام کردند. بدین منظور، آنها ۲۹ نسبت مالی را برای شرکت‌های تولیدی درمانده مالی بر اساس ماده ۱۴۱ قانون تجارت و به همان تعداد شرکت سالم به‌صورت تصادفی از شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران در بازه زمانی ۱۳۸۵ تا ۱۳۹۵ در نظر گرفتند و از صورت‌های مالی حسابرسی شده برای یک، دو و سه سال قبل از درماندگی استفاده کردند. در انتها به کمک ماشین بردار پشتیبان، درماندگی مالی را پیش‌بینی کردند. نتایج نشان داد، مدل پیشنهادی در یک، دو و سه سال پیش از وقوع درماندگی مالی، به‌طور معناداری برای پیش‌بینی درماندگی در مقایسه با دو روش رگرسیون لجستیک و آلتمن عملکرد بهتری دارد.

روش‌شناسی پژوهش

یادگیری ماشین سریع مبتنی بر کرنل

یادگیری ماشین سریع مبتنی بر کرنل (KELM) از تکنیک‌های یادگیری جدید و توسعه‌یافته در سال‌های اخیر است. این مدل از مدل یادگیری ماشین سریع تکامل یافته‌تر است و به‌طور متوسط در بسیاری از برنامه‌های کاربردی اتکاپذیرتری خود را نشان داده است. مدل یادگیری ماشین سریع، در ابتدا برای شبکه‌های عصبی تک‌لایه پنهان پیشخور پیشنهاد شد، سپس برای شبکه‌های عصبی تک‌لایه پنهان پیشخور تعمیم‌یافته گسترش داده شد. تابع خروجی شبکه‌های عصبی تک‌لایه پنهان پیشخور تعمیم‌یافته به‌صورت زیر است (وانگ و همکاران^۱، ۲۰۱۷).

$$f_L(x) = h(x)\beta = \sum_{i=1}^L \beta_i h_i(x) \quad \text{رابطه ۱}$$

در اینجا $\beta = [\beta_1, \dots, \beta_L]^T$ نشان‌دهنده بردار وزن خروجی بین لایه پنهان از گره‌های L و گره خروجی است، در نتیجه، خروجی لایه پنهان مربوط به ورودی x به‌عنوان بردار $h(x) = [h_1(x), \dots, h_L(x)]$ است. تابع $f_L(x)$ نیز تابع خروجی شبکه‌های عصبی تک‌لایه پنهان پیشخور تعمیم یافته است.

در واقع، تابع $h(x)$ فضای d بعدی ورودی را به فضای L بعدی نگاشت می‌کند. ساختار شبکه‌های عصبی دارای سه لایه ورودی، پنهان و خروجی است. بین لایه پنهان و لایه خروجی وزن وجود دارد و با بهینه‌کردن این وزن‌ها می‌توان به کمترین خطا در پیش‌بینی دست یافت. ادعا می‌شود که اگر نگاشت مناسبی در لایه پنهان انتخاب شود می‌توان هر تابعی را توسط این مدل تخمین زد. برخلاف روش‌های معمول یادگیری، مدل یادگیری ماشین سریع^۲ نه تنها می‌کوشد خطای داده‌های آموزش را حداقل کند، بلکه برای حداقل کردن نرم وزن‌های خروجی نیز تلاش می‌کند. بر اساس تئوری بارتلت^۳ برای شبکه‌های عصبی پیشخور تک‌لایه پنهان^۴، کاهش نرم وزن‌ها در کنار کاهش خطای آموزش به تعمیم‌پذیری بهتری می‌رسد. بنابراین، تابع هدف ماشین یادگیری سریع که می‌کوشد خطای آموزش و نرم وزن‌های خروجی را کاهش دهد، به‌صورت زیر است (وانگ و همکاران، ۲۰۱۷):

$$\text{Min } \|H\beta - T\|^2 \text{ and } \|\beta\| \quad \text{رابطه ۲}$$

که H در آن ماتریس لایه پنهان است و به‌صورت زیر تعریف می‌شود و T نیز تعداد تکرار را نشان می‌دهد.

$$H = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} h_1(x_1) & \dots & h_L(x_1) \\ \vdots & \vdots & \vdots \\ h_1(x_N) & \vdots & h_L(x_N) \end{bmatrix} \quad \text{رابطه ۳}$$

1. Wang and et al.
3. Bartlett's Theory

2. ELM
4. Single hidden layer feed- forward neural networks

معنای واقعی به حداقل رساندن هنجارهای وزن خروجی $\|\beta\|$ این است که فاصله حاشیه‌های مجزای طبقه‌های مختلف در فضای مشخصه روش یادگیری ماشین سریع را به حداکثر برسانیم. روش کمترین مربع استاندارد حداقل^۱ نیز در روش یادگیری ماشین سریع استفاده می‌شود.

$$\beta = H^{\dagger}T \quad \text{رابطه ۴}$$

که H^{\dagger} معنای معکوس ماتریس تعمیم‌یافته مور پنروز (MP) است.

یکی از مسائل مهمی که باید به آن توجه شود این است که چنانچه کاربران با نگاهت ویژگی‌های آشنایی ندارند یا زمانی که موضوع مطالعه چند کلاسه است و تفکیک آنها با یک محور خطی امکان‌پذیر نیست (هوانگ^۲ و همکاران، ۲۰۱۲)، باید از ماتریس کرنل استفاده شود که به آن تابع نگاهت کرنل گفته می‌شود. تابع نگاهت کرنل برای روش یادگیری ماشین سریع با استفاده از رابطه زیر به دست می‌آید:

$$\Omega_{ELM} = HH^T: \Omega_{ELM} i,j = h(x_i) \cdot h(x_j) = K(x_i, x_j) \quad \text{رابطه ۵}$$

جایی که $h(x)$ تابع نگاهت است، کرنل فضای ورودی داده‌ها را به شکلی نگاهت می‌کند که در H فضای مشخصه لایه پنهان بتوان با اطمینان به صورت خطی خروجی‌ها را از هم جدا کرد (وانگ و همکاران، ۲۰۱۷). برای محاسبه معکوس ماتریس تعمیم‌یافته مور پنروز؛ یعنی $H^{\dagger} = H^T (HH^T)^{-1}$ ، مقدار ثابت مثبت C به قطر HH^T رویکرد پیش‌بینی متعامد پیشنهاد می‌شود. به‌طور خلاصه، عملکرد خروجی روش یادگیری ماشین سریع به شکل زیر بیان می‌شود:

$$f(x) = h\beta = h(x)H^{\dagger} \left(\frac{I}{C} + HH^{\dagger} \right)^{-1} T = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T \left(\frac{I}{C} + \Omega_{ELM} \right)^{-1} T \quad \text{رابطه ۶}$$


همان‌طور که در شکل زیر نشان داده شده است، کاربران مجبور نیستند مشخصه لایه پنهانی که با ترفند کرنل مقابله می‌کند، شناسایی کنند و معمولاً، تابع کرنل پذیرفته شده است. تابع کرنل پایه شعاعی همیشه به این صورت^۳ $K(x, x_i) = \exp(-\gamma \|x, x_i\|)$ تعریف می‌شود. این دو پارامتر حیاتی که در تابع کرنل پایه شعاعی ارائه شده، پارامتر جریمه C و پارامتر کرنل گاما γ هستند.

الگوریتم گرگ خاکستری

به‌تازگی میرجلیلی، میرجلیلی و لوئیس^۳ (۲۰۱۴) نوعی الگوریتم بهینه‌سازی هوش ازدحامی به‌نام الگوریتم گرگ

1. Minimal normal least square method
2. Huang
3. Mirjalili, Mirjalili, & Lewis

خاکستری را معرفی کرده‌اند. در واقع، این الگوریتم خلاق سلسله‌مراتب اجتماعی و رفتار شکار گرگ خاکستری در طبیعت را شبیه‌سازی می‌کند. برای مدل‌سازی رفتار سلسله‌مراتبی اجتماعی گرگ خاکستری، این گروه به چهار گروه دسته‌بندی می‌شود: آلفا (α)، بتا (β)، دلتا (δ) و امگا (ω) که در شکل ذیل نشان داده شده است.



شکل ۱. سلسله‌مراتب شکار گروهی

هنگام طراحی الگوریتم بهینه‌ساز گرگ خاکستری، به منظور مدل‌سازی ریاضی سلسله‌مراتب اجتماعی گرگ‌ها، مناسب‌ترین راه‌حل را به صورت آلفا (α) در نظر می‌گیریم. متعاقباً، دومین و سومین راه مناسب به ترتیب بتا (β) و دلتا (δ) هستند. بقیه راه‌حل‌های کاندید به صورت امگا (ω) فرض می‌شوند. در الگوریتم GWO شکار (بهینه‌سازی) با کمک $\alpha - \beta - \delta$ صورت می‌گیرد. گرگ‌های ω از این سه گرگ تبعیت می‌کنند. به منظور مدل‌سازی ریاضی رفتار محاصره، رابطه‌های زیر پیشنهاد می‌شود.

$$\vec{D} = |\vec{C} \cdot \vec{X}_{P(t)} - \vec{X}(t)| \quad \text{رابطه ۷}$$

$$\vec{X}(t+1) = \vec{X}_{P(t)} - \vec{A} \cdot \vec{D} \quad \text{رابطه ۸}$$

که t نشان‌دهنده تکرار فعلی؛ $\vec{X}_{P(t)}$ بردار موقعیت جاری طعمه؛ $\vec{X}(t)$ نشان‌دهنده بردار موقعیت یک گرگ خاکستری و \vec{D} فاصله بین طعمه و گرگ‌هاست. بردارهای ضرب \vec{A} و \vec{C} با استفاده از رابطه‌های زیر محاسبه می‌شوند:

$$\vec{A} = 2a\vec{r}_1 - \vec{a} \quad \text{رابطه ۹}$$

$$\vec{C} = 2\vec{r}_2 \quad \text{رابطه ۱۰}$$

\vec{r}_1 و \vec{r}_2 بردارهای تولید و به صورت تصادفی در بازه $[0, 1]$ هستند. مؤلفه \vec{a} در طول تکرار از ۲ تا صفر به صورت خطی کاهش پیدا می‌کند.

با توجه به اینکه در فضای جست‌وجوی اولیه، ایده‌ای در خصوص موقعیت صید نداریم، فرض می‌کنیم که آلفا بهترین کاندید برای حل است و بتا و دلتا بهترین دانش را برای موقعیت صید دارند. بنابراین، سه جواب بهتری را که تاکنون داریم حفظ کرده و سایر عامل‌ها از قبیل امگا را مجبور می‌کنیم که موقعیت خودشان را با توجه به موقعیت بهترین عامل‌ها به‌روز کنند که در آن، رابطه‌های ۱۱، ۱۲ و ۱۳ مدل‌سازی ریاضی شکار و نزدیک‌شدن به طعمه (مقدار بهینه) را نشان می‌دهند:

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad \text{رابطه (۱۱)}$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \quad \text{رابطه (۱۲)}$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad \text{رابطه (۱۳)}$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha) \quad \text{رابطه (۱۴)}$$

$$\vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta) \quad \text{رابطه (۱۵)}$$

$$\vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \quad \text{رابطه (۱۶)}$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad \text{رابطه (۱۷)}$$

\vec{X}_α نشان‌دهنده موقعیت آلفا؛ \vec{X}_β نشان‌دهنده موقعیت بتا؛ \vec{X}_δ نشان‌دهنده موقعیت دلتا؛ \vec{X} نشان‌دهنده موقعیت جواب فعلی و \vec{C}_1 ، \vec{C}_2 و \vec{C}_3 بردارهایی هستند که به‌طور تصادفی تولید می‌کنند. فاصله تقریبی بین جواب فعلی، بر اساس رابطه‌های ۱۱ تا ۱۳ محاسبه می‌شود. رابطه‌های ۱۴ تا ۱۷ پس از تعریف فاصله، موقعیت نهایی راه‌حل جاری را محاسبه می‌کنند که در آن \vec{A}_1 ، \vec{A}_2 و \vec{A}_3 بردارهای تصادفی هستند و t نشان‌دهنده تعداد تکرار است. همان‌گونه که از رابطه‌های فوق دیده شود، اندازه گام گرگ‌های امگا که بعد از آلفا، بتا و دلتا اجرا می‌شوند (می‌دوند)، به‌ترتیب توسط رابطه‌های ۱۱ تا ۱۳ تعریف شده است. موقعیت نهایی گرگ‌های امگا نیز بر اساس رابطه‌های ۱۴ تا ۱۷ به‌دست می‌آید.

الگوریتم گرگ خاکستری بر مبنای KELM

همان‌طور که در بالا بیان شد، مدل KELM، عمدتاً توسط دو پارامتر اصلی C و γ کنترل می‌شود. در این پژوهش، یک الگوریتم بهینه‌سازی جهانی که به‌تازگی توسعه‌یافته و الگوریتم گرگ خاکستری نامیده می‌شود، برای شناسایی دو پارامتر

در KELM معرفی کردیم. روش KELM تکاملی که GWO-KELM نامیده می‌شود، استراتژی الگوریتم گرگ خاکستری را برای انطباق‌پذیری دو پارامتر کلیدی در KELM به کار می‌گیرد. در طراحی برازش به دقت طبقه‌بندی توجه می‌شود:

$$F = avgACC = \frac{(\sum_{i=1}^K testACC_i)}{K} \quad \text{رابطه ۱۸}$$

که $avgACC$ در تابع F ، دقت آزمونی را نشان می‌دهد که از طریق روش بهینه‌سازی ۱۰ طبقه برای طبقه‌بندی KELM به دست آمده است.

$$ACC = \frac{TP + FN}{TP + FP + TN + FN} \times 100\% \quad \text{رابطه ۱۹}$$

$$Type\ I\ error = \frac{FP}{FP + TN} \times 100\% \quad \text{رابطه ۲۰}$$

$$Type\ II\ error = \frac{FN}{TP + FN} \times 100\% \quad \text{رابطه ۲۱}$$

رابطه ۱۹ دقت آزمون را بررسی می‌کند که خود به دو بخش، خطای نوع اول (رابطه ۲۰) و خطای نوع دوم (رابطه ۲۱) دسته‌بندی می‌شود.

| | | |
|----------|--------------------|----------------|
| پیش‌بینی | | |
| ← | | → |
| ↑ | ماتریس درهم‌ریختگی | ورشکسته |
| | سالم | ورشکسته نادرست |
| ↓ | سالم | ورشکسته درست |
| واقعی | ورشکسته | ورشکسته درست |
| | سالم نادرست | |

شکل ۲. ماتریس درهم‌ریختگی

TP = سالم درست؛ یعنی شرکت‌هایی که سالم‌اند و مدل به‌درستی آنها را سالم تشخیص داده است.

TN = ورشکسته درست؛ شرکت‌هایی که ورشکسته‌اند و ورشکسته نیز تشخیص داده شوند.

FP = سالم نادرست؛ شرکت‌هایی که ورشکسته‌اند و مدل به‌اشتباه سالم تشخیص داده است.

FN = ورشکسته نادرست؛ شرکت‌هایی که سالم‌اند و به‌اشتباه ورشکسته تشخیص داده شوند.

خطای نوع اول: مثبت کاذب، شرکت ورشکسته را شرکت سالم قلمداد کنیم.

خطای نوع دوم: منفی کاذب، شرکت سالم را در دسته شرکت‌های ورشکسته طبقه‌بندی کنیم.

معیار مهم دیگری که برای تعیین میزان کارایی مدل طبقه‌بندی استفاده می‌شود، معیار ناحیه تحت منحنی ROC

است. ناحیه تحت منحنی، نشان‌دهنده سطح زیرنمودار ROC^۱ است که هر چه مقدار این عدد در مدل بزرگ‌تر باشد،

کارایی نهایی مدل مطلوب‌تر ارزیابی می‌شود. نمودار ROC روشی برای بررسی کارایی مدل‌هاست. در واقع، منحنی‌های

ROC منحنی‌هایی دو بعدی هستند که در آن درصد تشخیص صحیح دسته مثبت^۲ روی محور Y و به‌طور مشابه،

درصد تشخیص غلط دسته منفی^۳ روی محور X رسم می‌شود. به بیان دیگر، منحنی ROC مصالحه نسبی میان سودها و

هزینه‌ها را نشان می‌دهد.

$$TPR = \frac{TP}{TP + FN} \times 100\% \quad \text{رابطه (۲۲)}$$

$$FPR = \frac{FP}{TN + FP} \times 100\% \quad \text{رابطه (۲۳)}$$

$$AUC = \frac{1 + TPR - FPR}{2} \times 100\% \quad \text{رابطه (۲۴)}$$

الگوریتم ژنتیک

الگوریتم‌های فراابتکاری زیادی در مقوله پیش‌بینی وجود دارند و هر یک نسبت به دیگری برتری‌هایی دارد که الگوریتم

ژنتیک نیز یکی از آنها به شمار می‌رود. همچنین با توجه به اینکه تا حدی به برتری الگوریتم‌ها در مقایسه با روش‌های

آماري پی برده شده است، لازم دانستیم به‌جای روش‌های آماری، از الگوریتم‌ها برای مقایسه استفاده کنیم. در این میان

با توجه به قابلیت‌های الگوریتم ژنتیک در به‌دام‌نیفتادن در نقاط بهینه محلی، سرعت آن در دستیابی به جواب و

همچنین، عمومیت و شناخته‌شدن آن در تحقیق‌های کار شده به‌عنوان الگوریتم پیش‌بین، برای این تحقیق مدل

1. Receiver Operating Characteristic (ROC)

2. True Positive Rate (TPR)

3. False Positive Rate (FPR)

مقایسه‌ای به کار گرفته شده است. تحقیق وانگ و همکاران (۲۰۱۷) نمونه‌ای از مقاله‌هایی است که از الگوریتم ژنتیک به‌عنوان مدل رقیب بهره برده است.

یافته‌های پژوهش

هدف اصلی این تحقیق پیش‌بینی ورشکستگی شرکت‌های تولیدی با استفاده از مدل GWO-KELM است. همچنین برای اعتبارسنجی، نتایج به‌دست‌آمده از این مدل با نتایج حاصل از مدل GA-KELM^۱ مقایسه خواهد شد. با توجه به اینکه ملاک ورشکستگی در این پژوهش ماده ۱۴۱ قانون تجارت در نظر گرفته شده است، تنها ۴۰ شرکت در سال‌های ۱۳۹۴ تا پایان خرداد ۱۳۹۷ مشمول ماده فوق بودند که چهار شرکت از آنها به‌دلیل نبود اطلاعات کافی از نمونه‌ها حذف و ۳۶ شرکت دیگر به‌عنوان گروه اول انتخاب شدند. برای گروه دوم نیز از بین شرکت‌های سالم، ۱۰۲ شرکت به‌طور تصادفی و با استفاده از تابع Randbetween در نرم‌افزار اکسل، انتخاب شد تا نسبت شرکت‌های سالم به ورشکسته ۳ به ۱ باشد. در مجموع، از داده‌های ۱۳۶ شرکت برای این پژوهش استفاده شده است. با توجه به پژوهش‌های صورت‌گرفته‌ای همچون زمیچی اوسکی^۲ (۱۹۸۷)، لین^۳ (۲۰۱۳)، کالو، چن^۴ (۲۰۱۱) و السون (۱۹۸۰)، برای به‌دست آوردن نتایج قابل اطمینان‌تر نسبت شرکت‌های سالم به شرکت‌های ورشکسته، ۳ در مقابل ۱ پیشنهاد شده است (چائو، هسیه و کیو^۵، ۲۰۱۷).

متغیرهای پژوهش

با توجه به پیشینه تحقیق، از نسبت‌های مالی شرکت‌ها به‌عنوان ورودی مدل استفاده شده است. بنابراین، متغیرهای مستقل مدل، نسبت‌های مالی و متغیر وابسته نیز تنها خروجی مدل، سالم یا ورشکسته‌بودن شرکت‌ها خواهد بود. متغیرهای مستقل در این پژوهش شامل ۱۰ قلم نسبت مالی است که در جدول زیر مشاهده می‌شود.

جدول ۱. متغیرهای مستقل

| ردیف | متغیر | ردیف | متغیر |
|------|--|------|---|
| ۱ | بازده دارایی‌ها | ۶ | گردش دارایی‌ها |
| ۲ | نسبت جاری | ۷ | ارزش بازار حقوق صاحبان سهام به کل بدهی‌ها |
| ۳ | سود انباشته به کل دارایی‌ها | ۸ | جریان نقد به کل بدهی‌ها |
| ۴ | نسبت سرمایه در گردش به دارایی‌ها | ۹ | نسبت دارایی‌های جاری به کل دارایی‌ها |
| ۵ | سود قبل از بهره و مالیات به کل دارایی‌ها | ۱۰ | نسبت وجه نقد |

منبع: وانگ و همکاران، ۲۰۱۷

1. Genetic Algorithm-based KELM
3. Lin
5. Chou, Hsieh, & Qiu

2. Zmijewski
4. Cao & Chen

با استناد به تحقیق وانگ و همکارانش در سال ۲۰۱۷، دو گروه ۳۰ تایی و ۱۰ تایی از نسبت‌های مالی انتخاب شد و هر دو گروه جداگانه آموزش دیدند و آزمون شدند. با توجه به تعدد نسبت‌ها در گروه ۳۰ تایی و بی‌ربط بودن برخی از آنها با مقوله ورشکستگی، مدل گمراه‌کننده شد و دقت کمتری ارائه کرد. اما در گروه ۱۰ تایی از نسبت‌ها، با توجه به رابطه مستقیم هر یک از آنها با مقوله ورشکستگی، در مقایسه با گروه ۳۰ تایی مدل عملکرد بهتری داشت. بنابراین، در این تحقیق از گروه نسبت‌های ۱۰ تایی استفاده شده است.

نحوه کارکرد مدل

- گام اول، جمع‌آوری داده‌های مورد نیاز.
- گام دوم، جداسازی شرکت‌ها: در این مرحله شرکت‌هایی که طبق تعریف ورشکسته محسوب می‌شوند یا به بیان دیگر، جزء شرکت‌های مشمول ماده ۱۴۱ قانون تجارت قرار دارند، از یکدیگر تفکیک می‌شوند. شایان ذکر است که شرکت‌هایی به‌عنوان شرکت ورشکسته در دوره t انتخاب شده‌اند که تا سه دوره قبل از آن ($t-3$) سالم بودند. به بیان بهتر، شرکتی که سه دوره سه‌ماهه متوالی سالم بوده و در دوره چهارم مشمول ماده ۱۴۱ شده است، به‌عنوان شرکت ورشکسته انتخاب شده است. منظور از t در این پژوهش دوره‌های سه‌ماهه است. گفتنی است مدل باید با تجزیه و تحلیل داده‌های سه دوره قبل شرکت‌ها که همه سالم و غیرورشکسته‌اند، پیش‌بینی کند که کدام شرکت در سال t ورشکسته یا سالم خواهد بود.
- گام سوم، محاسبه نسبت‌های مالی.
- گام چهارم، استاندارد کردن نسبت‌های مالی: نرمال کردن داده‌ها به این دلیل لازم است که اگر داده‌های دو نرون در محدوده متفاوت قرار داشته باشند، نرونی که مشتمل بر مقادیر مطلق بزرگ‌تر است، طی یادگیری ترجیح داده می‌شود. همچنین، در صورتی که اطلاعات استفاده‌شده در شبکه عصبی به حد مناسبی مقیاس‌بندی نشود، شبکه هنگام یادگیری به یک نقطه همگرا نخواهد شد یا نتایج معناداری نخواهد داد. از طرف دیگر، اصولاً، وارد کردن داده‌های خام به الگوریتم موجب می‌شود سرعت و دقت شبکه کاهش یابد. برای اجتناب از چنین وضعیتی و همچنین به‌منظور یکسان‌سازی ارزش آنها، داده‌های ورودی می‌بایست استاندارد شوند؛ یعنی همه داده‌ها بین صفر و یک معادل‌سازی شوند. رابطه نرمال‌سازی به روش زیر است:

$$x_n = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad \text{رابطه ۲۵}$$

- گام پنجم، طبقه‌بندی داده‌ها با استفاده از روش اعتبارسنجی متقاطع به ۱۰ طبقه: در این مرحله یک‌دهم داده‌ها برای آزمون کنار گذاشته می‌شود و نهم بقیه داده‌ها با به‌اصطلاح داده‌های آموزش‌دیده، توسط مدل KELM تعلیم داده می‌شوند. سپس با توجه به لزوم بهینه‌سازی جفت پارامتر مدل یادشده، الگوریتم گرگ خاکستری داده‌های آموزش را به کار می‌گیرد تا پارامترهای فوق را بهینه کند. این الگوریتم برای بهینه‌سازی پارامترها، ۹ طبقه داده

ورودی را به کار می‌گیرد و در نهایت، دو پارامتر بهینه در رابطه با داده‌های مدنظر را در اختیار مدل KELM قرار می‌دهد تا دقت را از روی داده‌های آموزش دیده ارائه کند. حال مدلی که آموزش دیده است با داده‌هایی که برای آزمون کنار گذاشته شده‌اند، آزمون می‌کنیم و دقت پیش‌بینی و خطاهای نوع اول و دوم را به دست می‌آوریم. این گام را ۱۰ مرتبه تکرار می‌کنیم با این تفاوت که داده‌ها در هر بار تکرار، تغییر خواهند کرد؛ یعنی طبقه‌ای از داده‌ها که برای آزمون کنار گذاشته بودیم به مدل وارد می‌کنیم و طبقه دیگر از داده‌ها را برای آزمون از مدل خارج می‌کنیم و پروسه یادگیری و بهینه‌سازی را دوباره برای این داده‌ها از سر می‌گیریم. این کار به اندازه‌ای تکرار خواهد شد که همه طبقات داده‌ها یک‌بار به‌عنوان داده‌های آزمون استفاده شوند. بدیهی است با علم به اینکه ۱۰ طبقه داده داریم، باید چرخه توضیح داده شده در بالا را ۱۰ بار انجام دهیم. در نهایت، از دقت و خطاهای نوع اول و دوم که حاصل هر طبقه از داده‌ها (۱۰ جواب) است، میانگین می‌گیریم که این میانگین جواب نهایی کل داده‌هاست.

آمار توصیفی

به‌منظور تجزیه و تحلیل متغیرها، ابتدا به ارائه آمار توصیفی داده‌ها می‌پردازیم که نتایج آن در جدول ۲ ارائه شده است. در این جدول علاوه بر نحوه محاسبه متغیرهای مستقل، مقادیر حداکثر، حداقل، میانگین و انحراف معیار هر یک از آنها در یک نمونه ۱۳۶ تایی از جامعه شرکت‌های بورسی مشاهده می‌شود.

جدول ۲. آمار توصیفی داده‌ها

| متغیرهای مستقل | | حداکثر | حداقل | میانگین | انحراف معیار |
|----------------|---|--------|-------|---------|--------------|
| X_1 | سود خالص به کل دارایی‌ها | ۰/۲۶ | ۰/۰۲ | ۰/۰۲ | ۰/۰۵ |
| X_2 | دارایی‌های جاری به بدهی‌های جاری | ۴/۷۰ | ۱/۲۹ | ۱/۲۹ | ۰/۷۴ |
| X_3 | سود انباشته به کل دارایی‌ها | ۰/۶۴ | ۰/۰۵ | ۰/۰۵ | ۰/۲۴ |
| X_4 | سرمایه در گردش به کل دارایی‌ها | ۰/۷۱ | ۰/۰۷ | ۰/۰۷ | ۰/۲۷ |
| X_5 | سود قبل از بهره و مالیات به کل دارایی‌ها | ۰/۲۶ | ۰/۰۳ | ۰/۰۳ | ۰/۰۵ |
| X_6 | فروش به کل دارایی‌ها | ۱/۰۷ | ۰/۲۴ | ۰/۲۴ | ۰/۲۰ |
| X_7 | ارزش بازار حقوق صاحبان سهام به کل بدهی‌ها | ۳۷/۹۶ | ۲/۸۰ | ۲/۸۰ | ۴/۲۸ |
| X_8 | جریان نقد به کل بدهی‌ها | ۱/۰۰ | ۰/۰۱ | ۰/۰۱ | ۰/۱۰ |
| X_9 | دارایی‌های جاری به کل دارایی‌ها | ۰/۹۹ | ۰/۶۳ | ۰/۶۳ | ۰/۲۱ |
| X_{10} | وجه نقد به بدهی‌های جاری | ۱/۸۹ | ۰/۰۸ | ۰/۰۸ | ۰/۱۸ |

تنظیمات الگوریتم‌ها

الگوریتم‌های گرگ خاکستری و ژنتیک پارامترهایی دارند که باید مقدار آنها تعیین شود. جهش و تقاطع پارامترهای الگوریتم ژنتیک و گرگ‌های آلفا، بتا، گاما و امگا، پارامترهای الگوریتم گرگ خاکستری هستند. مقدار این پارامترها باید به‌نحوی تعیین شود که به جواب بهینه در مدل منجر شود. تعیین آنها توسط الگوریتم‌ها انجام می‌شود. این مقادیر در ابتدا

به‌صورت تصادفی و توسط خود الگوریتم تعیین می‌شوند، سپس با هر تکرار مقادیر فوق تغییر می‌کنند تا به بهینه‌ترین جواب دست یابند. مقدار اولیه جهش $0/5$ و مقدار اولیه تقاطع $0/99$ است. اما الگوریتم گرگ خاکستری مقادیر اولیه خود را به‌صورت تصادفی تعیین می‌کند. تعداد تکرار در هر دو الگوریتم ۱۵۰ در نظر گرفته شده است. الگوریتم گرگ خاکستری در ۵۱ تکرار و الگوریتم ژنتیک در ۷۲ تکرار به مقادیری دست یافتند که جواب بهینه را ارائه می‌کند.

جدول ۳. جزئیات نتایج به‌دست‌آمده از مدل GWO-KELM

| دسته | پارامترهای بهینه (C,y) | دقت آموزش Tr-acc | دقت آزمون Te-acc | خطای نوع اول Ty-I-e | خطای نوع دوم Ty-II-e | ناحیه تحت منحنی AUC |
|------|------------------------|------------------|------------------|---------------------|----------------------|---------------------|
| ۱ | (۳/۷۵۹ , ۰/۲۶۲) | ۱ | ۰/۹۲۶۷ | ۰/۰۶۱۲ | ۰/۰۵۱۵ | ۰/۹۱۳۶ |
| ۲ | (۱۹/۶۸۲ , ۰/۲۵۸) | ۰/۹۹۹۸ | ۰/۹۰۴۳ | ۰/۱۲۱۵ | ۰/۱۲۵۴ | ۰/۹۰۲۶ |
| ۳ | (۸/۹۱۶ , ۰/۱۰۳) | ۰/۹۹۹۸ | ۰/۸۸۶۸ | ۰/۰۵۶۲ | ۰/۱۰۲۹ | ۰/۹۶۴۶ |
| ۴ | (۳۲/۰۲۴ , ۰/۸۶۴) | ۰/۹۹۹۹ | ۰/۹۱۲۰ | ۰/۰۹۱۹ | ۰/۱۳۲۲ | ۰/۸۴۸۱ |
| ۵ | (۱/۲۰۹ , ۰/۸۶۴) | ۰/۹۹۹۸ | ۰/۹۲۴۲ | ۰/۰۸۰۵ | ۰/۰۸۲۹ | ۰/۸۸۱۲ |
| ۶ | (۵/۶۲۹ , ۰/۰۵۳) | ۱ | ۰/۸۹۴۹ | ۰/۱۰۳۸ | ۰/۰۷۱۴ | ۰/۸۵۳۴ |
| ۷ | (۴/۹۲۲ , ۰/۴۹۲) | ۰/۹۹۹۸ | ۰/۹۰۲۲ | ۰/۰۸۱۲ | ۰/۰۹۱۱ | ۰/۸۹۱۴ |
| ۸ | (۱۲/۹۵۱ , ۰/۳۵۷) | ۱ | ۰/۸۸۹۵ | ۰/۰۷۵۶ | ۰/۱۲۲۳ | ۰/۹۱۸۲ |
| ۹ | (۱۵/۶۳۸ , ۰/۴۶۷) | ۰/۹۹۹۸ | ۰/۸۹۹۱ | ۰/۱۱۴۴ | ۰/۱۰۶۵ | ۰/۹۵۳۲ |
| ۱۰ | (۳/۴۸۸ , ۰/۱۸۳) | ۱ | ۰/۹۰۴۳ | ۰/۰۹۵۲ | ۰/۰۹۳۴ | ۰/۹۴۲۸ |
| | میانگین | ۰/۹۹۹۹ | ۰/۹۰۴۴ | ۰/۰۸۸۲ | ۰/۰۹۸۰ | ۰/۹۰۶۹ |
| | انحراف معیار | ۰/۰۰۰۱ | ۰/۰۱۳۳ | ۰/۰۲۱۴ | ۰/۰۲۵۳ | ۰/۰۳۹۷ |

جدول ۳ نتایج مدل GWO-KELM شامل درصد دقت، درصد خطاها و میزان کارایی را نشان می‌دهد. با توجه به اینکه برای جلوگیری از بیش‌برازش^۱ از k-fold استفاده شده است، داده‌ها به ۱۰ طبقه تقسیم شدند. k-fold هنگام اجرا برای هر طبقه جواب جداگانه‌ای ارائه می‌دهد. تفاوت هر طبقه در داده‌های آموزش آنهاست؛ به طوری که در مرحله اول، مدل ۱۲۳ شرکت را به‌عنوان داده آموزش انتخاب می‌کند و از آنها آموزش می‌بیند و روی ۱۳ شرکت مابقی خود را آزمایش می‌کند و نتایج با عنوان fold اول ثبت می‌شوند. در مرحله دوم، مدل ۱۳ شرکت آزمایشی را وارد مدل کرده و ۱۳ شرکت دیگر را برای آزمایش از ۱۲۳ شرکت قبلی تفکیک می‌کند و دوباره نتایج را با عنوان fold دوم ثبت می‌کند. این مراحل ۱۰ بار تکرار می‌شود تا تمام داده‌ها یک‌بار به‌عنوان آموزش و یک‌بار به‌عنوان آزمایش در مدل استفاده شوند تا نتایجی همانند جدول ۳ استخراج شود.

در اینجا دقت داده‌های آموزش که مدل آنها را قبلاً شناخته است، تقریباً نزدیک به ۱۰۰ درصد بوده و کاملاً طبیعی است. اما نتیجه مهم که همان دقت داده‌های آزمون است، بیش از ۹۰ درصد بود که نتیجه بسیار خوبی است. خطای نوع

1. Over fitting

اول که طبقه‌بندی اشتباه شرکت‌های سالم به‌عنوان ورشکسته را نشان می‌دهد، به‌طور متوسط ۸/۸۲ درصد است و خطای نوع دوم که طبقه‌بندی اشتباه شرکت‌های ورشکسته به‌عنوان سالم را نشان می‌دهد، به‌طور متوسط ۹/۸ درصد است. احتمالاً اختلاف خطای نوع اول و دوم نشئت گرفته از نسبت ۳ به ۱ شرکت‌های سالم به ورشکسته است؛ به‌طوری که در صورت مساوی بودن تعداد شرکت‌های ورشکسته و سالم، این خطاها به هم نزدیک می‌شوند. کارایی مدل نیز به‌طور متوسط ۹۰/۶۹ درصد به دست آمد.

آزمون فرضیه

برای تأیید فرضیه پژوهش که برتری الگوریتم گرگ خاکستری نسبت به الگوریتم ژنتیک را نشان دهد، از جدول‌های ۴ و ۵ بهره می‌بریم.

جدول ۴. مقایسه الگوریتم گرگ خاکستری با الگوریتم ژنتیک

| FN = ۱۰ | FP = ۳ | TN = ۳۱ | TP = ۹۲ | GWO-KELM |
|---------|--------|---------|---------|----------|
| FN = ۱۴ | FP = ۴ | TN = ۳۰ | TP = ۸۸ | GA-KELM |

TP = سالم درست؛ یعنی شرکت‌هایی که سالم‌اند و مدل به‌درستی سالم تشخیص داده است.

TN = ورشکسته درست؛ شرکت‌هایی که ورشکسته‌اند و ورشکسته تشخیص داده شده‌اند.

FP = سالم نادرست؛ شرکت‌هایی که ورشکسته‌اند؛ اما مدل به‌اشتباه سالم تشخیص داده است.

FN = ورشکسته نادرست؛ شرکت‌هایی که سالم‌اند؛ اما به‌اشتباه ورشکسته تشخیص داده شده‌اند.

با توجه به تعریف‌های بالا، جدول ۴ نشان می‌دهد، مدل GWO-KELM از بین ۱۰۲ شرکت سالم، ۹۲ شرکت را به‌درستی سالم اعلام کرده است، در حالی که مدل GA-KELM توانسته است ۸۸ شرکت را به‌درستی سالم اعلام کند. همچنین مدل GWO-KELM از بین ۳۴ شرکت ورشکسته، ۳۱ شرکت را به‌درستی ورشکسته اعلام کرده، در حالی که مدل GA-KELM ۳۰ شرکت را ورشکسته تشخیص داده است. در نتیجه مدل GWO-KELM سه شرکت ورشکسته را به‌اشتباه سالم و ۱۰ شرکت سالم را به‌اشتباه ورشکسته تشخیص داده است. مجموع اشتباهات مدل GWO-KELM ۱۳ شرکت از ۱۳۶ شرکت و مجموع اشتباهات مدل رقیب ۱۸ شرکت بوده است.

جدول ۵. دقت و خطاهای نوع اول و دوم

| Equation | Method | GWO-KELM | GA-KELM |
|--|--------|----------|---------|
| $ACC = \frac{TP + FN}{TP + FP + TN + FN} \times 100$ | | ۹۰/۴۴ | ۸۶/۷۶ |
| $Type I error = \frac{FP}{FP + TN} \times 100$ | | ۸/۸۲ | ۱۱/۷۶ |
| $Type II error = \frac{FN}{FN + TP} \times 100$ | | ۹/۸۰ | ۱۲/۵۰ |

با استفاده از نتایج جدول ۴ و رابطه‌های جدول ۵، می‌توان میزان دقت و خطاهای نوع اول و دوم را به صورت دستی محاسبه کرد.

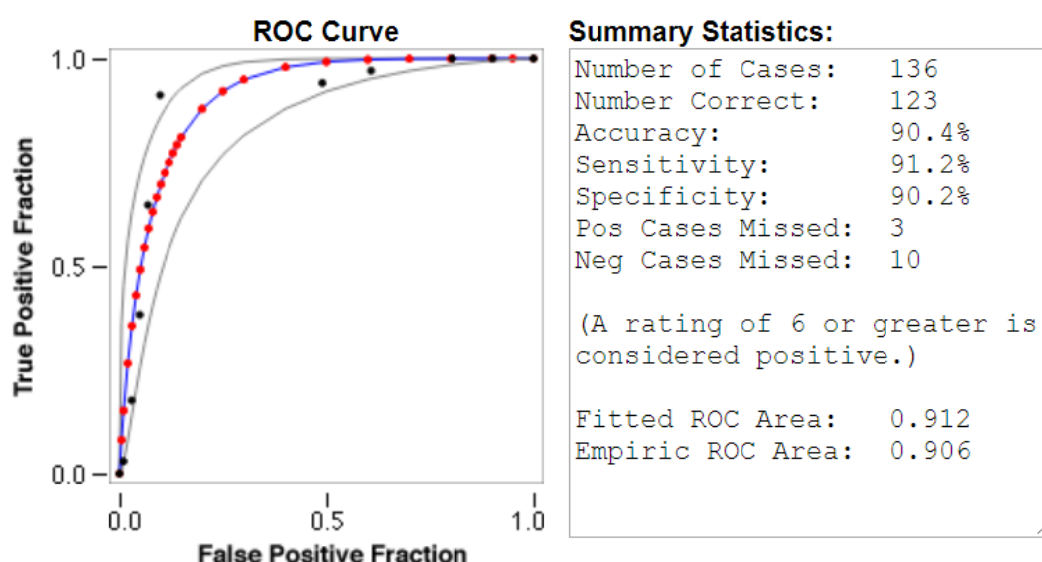
خطای نوع اول: مثبت کاذب، شرکت ورشکسته را سالم قلمداد کنیم.

خطای نوع دوم: منفی کاذب، شرکت سالم را در دسته ورشکسته قرار دهیم.

با توجه به نتیجه محاسبه رابطه‌های مندرج در جدول ۵، دقت پیش‌بینی در مدلی که از الگوریتم گرگ خاکستری استفاده شده ۹۰ درصد است؛ اما دقت پیش‌بینی در مدلی که از الگوریتم ژنتیک استفاده شده ۸۷ درصد به دست آمده است. همچنین خطاهای نوع اول و دوم به ترتیب در الگوریتم گرگ خاکستری ۸/۸۲ و ۹/۸ درصد است؛ اما در الگوریتم ژنتیک ۱۱/۷۶ و ۱۲/۵ درصد است.

ناحیه تحت منحنی ROC

همان طور که در جدول ۶ مشاهده می‌شود، مدل یادگیری که به وسیله الگوریتم گرگ خاکستری بهینه شده، در مقایسه با بهینه‌ساز ژنتیک، در معیار کارایی نیز همانند سایر معیارها عملکرد بهتری داشته است. AUC معیاری تعیین‌کننده برای سنجش عملکرد مدل‌های طبقه‌بندی دودویی است، هر چه این معیار به ۱ نزدیک باشد، نشان‌دهنده کارایی بهتر مدل مدنظر است. معیار ناحیه تحت منحنی ROC برای الگوریتم گرگ خاکستری در این پژوهش ۰/۹۰۶ و برای الگوریتم ژنتیک ۰/۸۷۸ به دست آمده است که نمودار و جزئیات آن به شرح زیر است (شکل ۳ و جدول ۶).



شکل ۳. منحنی ROC

جدول ۶. محاسبه ناحیه تحت منحنی ROC

| Method | GWO-KELM | GA-KELM |
|----------------------------|----------|---------|
| $TPR = \frac{TP}{TP + FN}$ | ۰/۹۰۲۰ | ۰/۸۷۵۰ |
| $FPR = \frac{FP}{FP + TN}$ | ۰/۰۸۸۲ | ۰/۱۱۷۶ |
| A | ۰/۹۰۶۹ | ۰/۸۷۸۷ |

ماتریس درهم‌ریختگی

روش دیگری که می‌توان از طریق آن دقت مدل‌های کار شده را بررسی کرد، ماتریس درهم‌ریختگی است که نتایج آن در جدول ۷ مشاهده می‌شود.

جدول ۷. ماتریس درهم‌ریختگی

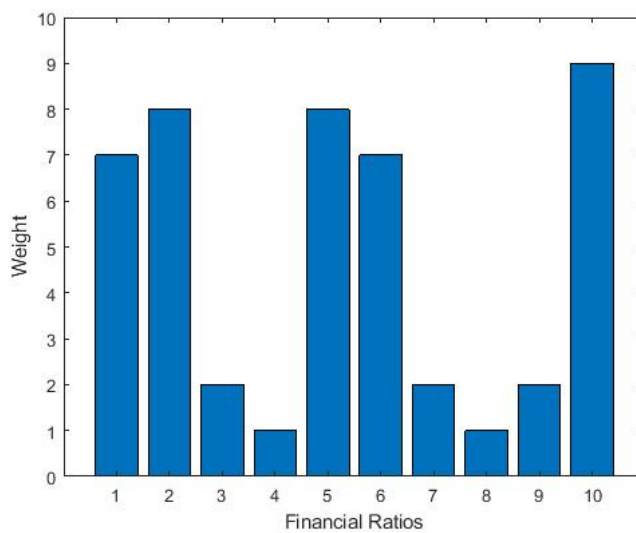
| مدل | خروجی | ورشکسته | سالم | دقت (%) |
|----------|---------|---------|------|---------|
| GWO-KELM | ورشکسته | ۳۱ | ۱۰ | ۹۱/۱۸ |
| | سالم | ۳ | ۹۲ | ۹۰/۱۹ |
| | جمع | ۳۴ | ۱۰۲ | ۹۰/۴۴ |
| GA-KELM | ورشکسته | ۳۰ | ۱۴ | ۸۸/۲۴ |
| | سالم | ۴ | ۸۸ | ۸۶/۲۷ |
| | جمع | ۳۴ | ۱۰۲ | ۸۶/۷۶ |

جدول ۷ طبقه‌بندی نادرست شرکت‌های ورشکسته به‌عنوان سالم و طبقه‌بندی نادرست شرکت‌های سالم به‌عنوان ورشکسته را برای دو مدل یاد شده نشان می‌دهد. از مجموع ۳۴ شرکت ورشکسته، الگوریتم گرگ خاکستری سه شرکت و الگوریتم ژنتیک چهار شرکت را در گروه سالم طبقه‌بندی کرده‌اند. همچنین از مجموع ۱۰۲ شرکت سالم، الگوریتم گرگ خاکستری ۱۰ شرکت و الگوریتم ژنتیک ۱۴ شرکت را ورشکسته تشخیص داده است. در نهایت، از مجموع ۱۳۶ شرکت سالم و ورشکسته، الگوریتم گرگ خاکستری ۱۳ خطا و الگوریتم ژنتیک ۱۸ خطا در طبقه‌بندی داشته است. بنابراین همان‌طور که در جدول ۵ مشاهده می‌شود، دقت مدل اول ۹۰ درصد و دقت مدل دوم ۸۷ درصد است.

وزن نسبت‌های مالی

شکل ۴ تأثیر یا وزن هر یک از نسبت‌های مالی در تحقق هدف تحقیق را نشان می‌دهد. به بیان دیگر، توان هر یک از نسبت‌های مالی برای تعیین ورشکستگی در نمودار زیر مشاهده می‌شود؛ به‌گونه‌ای که هر نسبتی به ۱۰ نزدیک‌تر باشد،

تأثیر بیشتر و هر نسبتی به سمت صفر میل کند، تأثیر کمتری در تعیین ورشکستگی دارد. ترتیب نسبت‌ها همان ترتیبی است که در جدول ۲ آورده شده است. نسبت‌های سود خالص به کل دارایی‌ها، دارایی‌های جاری به بدهی‌های جاری، سود قبل از بهره و مالیات به کل دارایی‌ها، فروش به کل دارایی‌ها و وجه نقد به بدهی‌های جاری، مؤثرترین متغیرها در تعیین ورشکستگی بوده‌اند.



شکل ۴. وزن نسبت‌ها در تعیین ورشکستگی

جمع‌بندی یافته‌ها

برای نمایش نتیجه نهایی پژوهش و درک بهتر آن و همچنین پاسخ‌گویی به هدف و تأیید فرضیه، جدول ۸ طراحی و ارائه شده است.

جدول ۸. جمع‌بندی نتایج به‌دست‌آمده از دو مدل متفاوت

| مدل | دقت آموزش | دقت آزمون | خطای نوع اول | خطای نوع دوم | ناحیه تحت منحنی |
|----------|-----------------|-----------------|-----------------|-----------------|-----------------|
| Method | Tr-acc | Te-acc | Ty-I-e | Ty-II-e | AUC |
| GWO-KELM | ۰/۹۹۹۹ ± ۰/۰۰۰۱ | ۰/۹۰۴۴ ± ۰/۰۱۳۳ | ۰/۰۸۸۲ ± ۰/۰۲۱۴ | ۰/۰۹۸۰ ± ۰/۰۲۵۳ | ۰/۹۰۶۹ ± ۰/۰۳۹۷ |
| GA-KELM | ۰/۹۷۶۰ ± ۰/۰۱۲۹ | ۰/۸۶۷۶ ± ۰/۰۲۸۶ | ۰/۱۱۷۶ ± ۰/۰۱۲۲ | ۰/۱۲۵۰ ± ۰/۰۱۱۹ | ۰/۸۷۸۷ ± ۰/۰۱۵۶ |

با توجه به جدول ۸، الگوریتم گرگ خاکستری به‌طور دقیق در دقت‌های آموزش و آزمون، خطاها و کارایی، از الگوریتم ژنتیک عملکرد بهتری از خود به نمایش گذاشته است. شایان ذکر است همه ارقام جدول ۸ حاصل میانگین دسته‌بندی ۱۰ تایی داده‌هاست و به همین دلیل انحراف معیار آنها نیز در مقابل هر عدد درج شده است. ناگفته نماند که انحراف معیارهای الگوریتم ژنتیک در خطاهای نوع اول و دوم و کارایی، کمتر از انحراف معیار الگوریتم گرگ خاکستری

است و از این موضوع می‌توان به‌عنوان قوت الگوریتم ژنتیک یاد کرد. اما این نکته نیز شایان توجه است که هدف اصلی مقاله، رسیدن به درصد خطای کم بود که با الگوریتم گرگ خاکستری به این مهم دست یافتیم. به بیان دیگر، الگوریتم ژنتیک در سطح درصد خطاهای زیاد، انحراف معیار کمتری نشان داده است؛ در حالی که الگوریتم گرگ خاکستری در سطح درصد خطاهای کم، انحراف معیار بیشتری دارد.

نکته دیگری که باید درباره الگوریتم‌های فرا ابتکاری دانست، نتایج متفاوت در هر بار اجراست. همه الگوریتم‌های فرا ابتکاری برای بهینه‌سازی پارامترها، به متغیرهای خود اعداد تصادفی می‌دهند، سپس با توجه به نتیجه مدل متغیرهای خود را به‌روزرسانی می‌کنند تا به جواب بهتری دست یابند. این مراحل را آنقدر تکرار می‌کنند که با به‌روزرسانی متغیرهای خود دیگر جواب بهتری حاصل نشود. در این پژوهش، تعداد تکرار به‌روزرسانی اعداد متغیرهای مربوط به الگوریتم‌ها ۱۵۰ در نظر گرفته شده است. الگوریتم گرگ خاکستری از تکرار ۵۱ به بعد و الگوریتم ژنتیک از تکرار ۷۲ به بعد دیگر به نتایج بهتری دست نیافتند. از این رو، پس از این مرحله هر چه به به‌روزرسانی متغیرهای خود اقدام کنند، نتیجه حاصل که همان دقت است، تغییر نخواهد کرد.

آزمون معناداری تفاوت میانگین

جدول ۹. آزمون معناداری دو مدل

| p-value (significance) | | | | | روش |
|------------------------|--------------|--------------|-----------|-----------|----------|
| ناحیه تحت منحنی | خطای نوع دوم | خطای نوع اول | دقت آزمون | دقت آموزش | |
| ۲/۰۸۷۳ | ۳/۰۴۳ | ۳/۸۰۶۳ | ۳/۷۳۸ | ۵/۸۵۸۳ | GWO-KELM |
| (۰/۰۵۸۶)* | (۰/۰۰۹۴) | (۰/۰۰۱۹) | (۰/۰۰۲۹) | (۰/۰۰۰۲) | |

*تنها معیاری که در سطح ۹۵ درصد معنادار نبود. اعداد داخل پرانتز مقادیر P-value را نشان می‌دهند.

برای نشان دادن معناداری تفاوت میانگین شاخص‌های حاصل شده از مدل‌های GA-KELM و GWO-KELM از جمله، دقت آموزش، دقت آزمون، خطای نوع اول، خطای نوع دوم و ناحیه تحت منحنی ROC، از آزمون t-test استفاده شد و نتایج مطابق جدول ۹ نشان داد که از بین پنج شاخص بررسی شده، چهار شاخص در سطح ۹۵ درصد اختلاف معناداری دارند. همچنین مشخص شد نتایج مدل‌ها در شاخص ناحیه تحت منحنی ROC، در میانگین اختلاف معناداری ندارد. به بیان دیگر، بر اساس نتایج این آزمون می‌توان گفت که افزایش دقت مدل GWO-KELM تصادفی نبوده و قابلیت تعمیم دارد.

نتیجه‌گیری

هدف از اجرای این تحقیق، پیش‌بینی ورشکستگی شرکت‌های تولیدی از طریق مدل یادگیری ماشین سریع مبتنی بر

کرنل بهینه‌شده با الگوریتم گرگ خاکستری بود. در این راستا ما از پنج معیار دقت آموزش، دقت آزمون، خطای نوع اول، خطای نوع دوم و ناحیه تحت منحنی (AUC) برای سنجش عملکرد آن استفاده کردیم. نتایج نشان داد این مدل می‌تواند به‌عنوان مدل قابل اعتماد در پیش‌بینی ورشکستگی توسط اعتباردهندگان، سرمایه‌گذاران و سایر ذی‌نفعان از جمله حوزه مدیریت داخلی شرکت استفاده شود. همان‌طور که الگوریتم گرگ خاکستری در مقایسه با رقبا در ۲۹ تابع معیار سنجش عملکرد استاندارد، بهترین عملکرد را ارائه کرده بود، در این تحقیق نیز نشان داد در چهار معیار از پنج معیار در دست بررسی، همانند پژوهش وانگ و همکاران (۲۰۱۷)، از رقیب خود یعنی الگوریتم ژنتیک، نتایج بهتری ارائه می‌دهد؛ به‌طوری‌که از ۱۳۶ شرکت بررسی‌شده به‌وسیله این مدل، ۱۲۳ شرکت درست پیش‌بینی شد و معیار دقت در آن ۹۰/۴۴ درصد، خطای نوع اول ۸/۸۲ درصد، خطای نوع دوم ۹/۸ درصد و ناحیه تحت منحنی ROC ۹۰/۶۹ درصد به دست آمد. همچنین نتیجه آزمون معناداری تفاوت میانگین نشان داد در میانگین نتایج دو مدل، اختلاف معناداری وجود دارد.

وانگ و همکارانش (۲۰۱۷) نیز همین مدل و همین نسبت‌ها را روی مجموعه داده‌های بورس ژاپن برای ۱۵۲ شرکت اجرا کردند و معیار دقت را ۸۷ درصد، خطای نوع اول را ۱۲/۳۲ درصد، خطای نوع دوم را ۱۳/۱۷ درصد و ناحیه تحت منحنی ROC را ۸۷/۱۱ درصد به دست آوردند. آنها این مدل را روی مجموعه ۲۴۰ داده بورس لهستان نیز پیاده کرده و از ۳۰ نسبت مالی استفاده کردند و این نتایج را به دست آوردند: معیار دقت ۸۵ درصد، خطای نوع اول ۱۷/۸۷ درصد، خطای نوع دوم ۱۳/۱۷ درصد و ناحیه تحت منحنی ROC ۸۵/۷۳ درصد. شایان ذکر است، تمامی معیارها در مدل استفاده‌شده از الگوریتم گرگ خاکستری نسبت به الگوریتم ژنتیک نتایج بهتری ارائه کرده‌اند. بنابراین با توجه به نتایج کسب‌شده از تحقیق حاضر، مدل GWO-KELM را می‌توان به‌عنوان مدلی قدرتمند در زمینه پیش‌بینی ورشکستگی برای استفاده‌کنندگان معرفی کرد.

پیشنهاد‌های کاربردی

۱. با توجه به دقت بیش از ۹۰ درصد مدل ارائه شده در این پژوهش، به نهادهای مالی اعتباردهنده، از جمله بانک‌ها و مؤسسه‌های اعتباری توصیه می‌شود هنگام وام‌دادن، از این مدل برای تشخیص توان بازپرداخت تسهیلات اعطا شده توسط وام‌گیرنده استفاده کنند.
۲. نهادهای سرمایه‌گذاری یا حتی سرمایه‌گذاران خرد نیز همانند نهادهای اعتباردهنده می‌توانند برای سرمایه‌گذاری در سهام شرکت‌ها از نتایج مدل بهره ببرند.
۳. با توجه به عملکرد خوبی که مدل یادگیری ماشین بهینه‌شده با الگوریتم گرگ خاکستری ارائه می‌دهد، برای پیش‌بینی ورشکستگی از این مدل به‌جای الگوریتم ژنتیک استفاده شود.

پیشنهاد‌های پژوهشی

مدل‌های مبتنی بر شبکه‌های عصبی، بر برآزش خروجی‌ها تمرکز می‌کنند، به همین دلیل روابط بین ورودی و خروجی و اتفاق‌های رخ داده در لایه‌ها و نرون‌ها از دید کاربر پنهان می‌ماند و کاربر توانایی گزینش، اصلاح یا توسعه قوانین نهفته را

ندارد. بر همین اساس، پیشنهاد می‌شود مدل‌های شبکه‌های عصبی با شیوه‌های داده‌کاوی تلفیق شوند تا شناسایی قوانین و میزان پشتیبانی از آنها امکان‌پذیر شود. همچنین، در این حالت تصمیم‌گیری بر اساس قوانین استخراج‌شده برای گروه تصمیم‌گیران عملی‌تر خواهد بود.

منابع

- بت‌شکن، محمدهاشم؛ سلیمی، محمد جواد؛ فلاح‌تگر متحدجو، سعید (۱۳۹۷). ارائه یک روش ترکیبی به‌منظور پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۰ (۲)، ۱۷۳-۱۹۲.
- خورشیدی، زهرا (۱۳۹۵). *ارائه مدل هشدار سریع مالی در صنایع خودرو و ماشین‌آلات بورس اوراق بهادار تهران و بررسی کارایی آن*. پایان‌نامه کارشناسی ارشد، تهران: دانشکده علوم دانشگاه خوارزمی.
- سعیدی، علی؛ آقایی، آرزو (۱۳۸۸). پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از شبکه‌های بیز. *بررسی‌های حسابداری و حسابرسی*، ۱۶ (۲)، ۵۹-۷۸.
- شاکری، عبدالرضا (۱۳۸۲). *بررسی کاربردی مدل اسپرینگیت برای پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران*. پایان‌نامه کارشناسی ارشد، تهران: دانشکده معارف اسلامی و مدیریت دانشگاه امام صادق.
- فلاح‌پور، سعید؛ ارم، اصغر (۱۳۹۵). پیش‌بینی درماندگی مالی شرکت‌ها با استفاده از الگوریتم کلونی مورچگان. *تحقیقات مالی*، ۱۸ (۲)، ۳۴۷-۳۶۸.
- فلاح‌پور، سعید؛ راعی، رضا؛ نوروزیان، عیسی (۱۳۹۷). استفاده از روش ترکیبی انتخاب ویژگی پی‌درپی پیشرو شناور و ماشین بردار پشتیبان در پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۰ (۳)، ۲۸۹-۳۰۴.
- فلاح‌پور، سعید؛ نوروزی‌یان لکوان، عیسی؛ هندیجانی زاده، محمد (۱۳۹۶). کاربرد روش ترکیبی ماشین بردار پشتیبان و انتخاب ویژگی به‌منظور پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۱۹ (۱)، ۱۳۹-۱۵۶.

References

- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, 23(4), 589-609.
- Atiya, A. F. (2001). Bankruptcy prediction for credit risk using neural networks: A survey and new results. *IEEE Transactions on neural networks*, 12(4), 929-935.
- Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of accounting research*, 4, 71-111.
- Botshekan, M.H., Salimi, M., Falahatgar Mottahedjoo, S. (2018). Developing a hybrid approach for financial distress prediction of listed companies in Tehran stock

- exchange. *Financial Research Journal*, 20 (2), 173-192. (in Persian)
- 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.
- Chou, C.-H., Hsieh, S.-C., & Qiu, C.-J. (2017). Hybrid genetic algorithm and fuzzy clustering for bankruptcy prediction. *Applied Soft Computing*, 56, 298-316.
- Fallahpour, S., Raei, R., Norouzian Lakvan, E. (2018). Applying Combined Approach of Sequential Floating Forward Selection and Support Vector Machine to Predict Financial Distress of Listed Companies in Tehran Stock Exchange Market. *Financial Research Journal*, 20(3), 289-304. (in Persian)
- Fallahpour, S., Eram, A. (2016). Predicting Companies Financial Distress by Using Ant Colony Algorithm. *Financial Research Journal*, 18(2), 347-368. (in Persian)
- Fallahpour, S., Raei, R., Norouzian Lakvan, E. Hendijani Zadeh, M. (2017). Use of Combined Approach of Support Vector Machine and Feature Selection for Financial Distress Prediction of Listed Companies in Tehran Stock Exchange Market. *Financial Research Journal*, 19(1), 139-156. (in Persian)
- Fedorova, E., Gilenko, E., & Dovzhenko, S. (2013). Bankruptcy prediction for Russian companies: Application of combined classifiers. *Expert systems with applications*, 40(18), 7285-7293.
- Gitman, G. M., & Parnas, A. (1996). *Method for production of spheroidized particles*. In: Google Patents.
- Guang-Bin, H., Babri, H.A. (1998). Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions. *IEEE Transactions on Neural Networks*, 9 (1), 224-229.
- Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4 (2), 251-257.
- Huang, G.B., Zhu, Q.Y., Siew, C.K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70 (1-3), 489-501.
- Khorshidi, Z. (2016). *Provide a fast financial warning model in the automotive industry and Tehran stock exchange machines and review its efficiency*. Governmental dissertation, Ministry of Science, Research and Technology, Kharazmi University of Tehran, Faculty of Finance Sciences. (in Persian)
- Leshno, M., Lin, V.Y., Pinkus, A., & Schocken, S. (1993). Multilayer feedforward networks with a nonpolynomial activation function can approximate any function. *Neural Networks*, 6 (6), 861-867.

- Min, J. H., & Lee, Y.-C. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert systems with applications*, 28(4), 603- 614.
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*, 18(1), 109- 131.
- Paramjeet, & Ravi, V. (2011). Bacterial foraging trained wavelet neural networks: application to bankruptcy prediction in banks. *International Journal of Data Analysis Techniques and Strategies*, 3 (3), 261-280.
- Ravi, V., & Pramodh, C. (2008). Threshold accepting trained principal component neural network and feature subset selection :Application to bankruptcy prediction in banks. *Applied Soft Computing*, 8 (4), 1539-1548.
- Saeedi, A., Aghaie, A. (2010). Predicting Financial Distress of firms Listed in Tehran Stock Exchange Using Bayesian networks. *Journal of Accounting and Auditing Review*, 16(2), 59- 78. (in Persian)
- Sarkar, S., & Sriram, R. S. (2001). Bayesian models for early warning of bank failures. *Management Science*, 47 (11), 1457-1475.
- Shah, J. R., & Murtaza, M. B. (2000). A neural network based clustering procedure for bankruptcy prediction. *American Business Review*, 18 (2), 80.
- Shakeri, A. (2003). *Applied study of Springate model for forecasting bankruptcy of companies accepted in Tehran Stock Exchange*. Master dissertation, Faculty of Islamic Sciences and Management of Imam Sadiq University in Tehran. (in Persian)
- Shin, K.-S., Lee, T. S., & Kim, H.-j. (2005). An application of support vector machines in bankruptcy prediction model. *Expert systems with applications*, 28 (1), 127-135.
- Tsai, C. -F., Wu, J.W.(2008). Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert Systems with Applications*, 34 (4), 2639–2649.
- Wang, M., Chen, H., Li, H., Cai, Z., Zhao, X., Tong, C., ..., Xu, X. (2017). Grey wolf optimization evolving kernel extreme learning machine: Application to bankruptcy prediction. *Engineering Applications of Artificial Intelligence*, 63, 54-68.
- Vasu, M., Ravi, V. (2011). Bankruptcy prediction in banks by principal component analysis threshold accepting trained wavelet neural network hybrid. In: *Proceedings of the International Conference on Data Mining*. USA.
- West, R. C. (1985). A factor-analytic approach to bank condition. *Journal of Banking & Finance*, 9 (2), 253-266.

- Zhang, G., Hu, Y.M., Patuwo, B.E., Indro, D.C. (1999). Artificial neural networks in bankruptcy prediction: general framework and cross-validation analysis. *European Journal of Operational Research*, 116 (1), 16–32.
- Zhao, D., Huang, C., Wei, Y., Yu, F., Wang, M., & Chen, H. (2017). An effective computational model for bankruptcy prediction using kernel extreme learning machine approach. *Computational Economics*, 49 (2), 325-341.