

Evaluating Credit Risk Based on Combined Model of Neural Network of Pattern Recognition and Ants' Colony Algorithm

Gholamreza Jandaghi¹ Professor, Faculty of Management and Accounting, Farabi Campus University of Tehran, Qom, Iran.

Alireza Saranj² Assistant Professor, Faculty of Management and Accounting, Farabi Campus University of Tehran, Qom, Iran (Author Corresponding).

Reza Rajaei³ Ph.D. of Financial Management, Faculty of Management and Accounting, Farabi Campus University of Tehran, Qom, Iran.

Ahmadreza Ghasemi⁴ Assistant Professor, Faculty of Management and Accounting, Farabi Campus University of Tehran, Qom, Iran.

Reza Tehrani⁵ Professor, Department of Financial Management., Faculty of Management, University of Tehran, Iran.

Abstract

A great amount of potential financial losses arise from borrowers' abstaining from refunding their debts calls and the development and improvement of credit risk measurement techniques in the financial literature in order to decrease such losses has transformed into an inevitable subject. The purpose of bankruptcy forecasting models is to estimate the probability of a company or a person's abstaining during a certain period of time. This research used the data gathered from a sample of 218 active companies in Tehran Stock Exchange Market as well as Over-The-Counter for the period between 1990 and 2016. Moreover, ants' colony algorithm was used to determine the most effective factors of credit risk and also pattern recognition neural network technique was applied to classify and evaluate the precision of bankruptcy forecasts. As a result, such ratios as profit before interests and taxes to total sale; total benefits of shareholders to debts; and current ratio, cash ratio and shareholders' benefits ratio to total assets are the most effective factors. Finally, the presented model which employs data belonging to one, two and three years before the intended year is able to forecast the credit condition of companies with higher precision as compared to the average precision of current models.

Keywords: Credit Risk, Bankruptcy Probability, Neural Network, Pattern Recognition Algorithm, Ants' Colony Aalgorithm.

1. jandaghi@ut.ac.ir

2. alisaranj@ut.ac.ir

3. r.rajaei@ut.ac.ir

4. ghasemiahmad@ut.ac.ir

5. rtehrani@ut.ac.ir

عنوان مقاله: ارزیابی ریسک اعتباری با استفاده از مدل

ترکیبی شبکه عصبی بازشناسی الگو و الگوریتم

مورچگان

غلامرضا جندقی^۱ - علیرضا سارنج^۲ - رضا رجائی^۳ -

احمدرضا قاسمی^۴ - رضا تهرانی^۵

مقاله پژوهشی

دریافت: ۱۳۹۸/۰۷/۱۵

پذیرش: ۱۳۹۹/۰۱/۲۱

چکیده:

میزان قابل توجه زیان مالی بالقوه ناشی از بازپرداخت نکردن تعهدهای وام‌گیرندگان است، و توسعه و بهبود روش‌های اندازه‌گیری ریسک اعتباری برای کاهش زیان مالی ناشی از نکول وام‌گیرندگان به موضوعی اجتناب‌ناپذیر در ادبیات مالی تبدیل شده است. هدف مدل‌های پیش‌بینی ورشکستگی، برآورد احتمال نکول شرکت یا شخص در یک دوره زمانی است. در پژوهش حاضر، از داده‌های شرکت‌های حاضر در بورس اوراق بهادار تهران و فرابورس در سال‌های ۱۳۷۰-۱۳۹۵ استفاده می‌شود و با نمونه‌ای از ۲۱۸ شرکت، الگوریتم کلونی مورچگان برای تعیین موثرترین عوامل ریسک اعتباری و روش شبکه عصبی بازشناسی الگو برای طبقه‌بندی و ارزیابی میزان دقت پیش‌بینی ورشکستگی استفاده می‌شود. نسبت‌هایی شامل سود قبل از بهره و مالیات به فروش کل، کل حقوق صاحبان سهام به کل بدهی، نسبت جاری، نسبت وجه نقد، و نسبت حقوق صاحبان سهام به دارایی کل به عنوان موثرترین عوامل شناسایی می‌شوند. مدل نهایی قادر به پیش‌بینی وضعیت اعتباری شرکت‌ها، با دقت بالاتری نسبت به متوسط دقت مدل‌های متداول موجود با استفاده از داده‌های سال قبل، دو سال قبل، و سه سال قبل از سال هدف برآورد است.

کلیدواژه‌ها: ریسک اعتباری، احتمال ورشکستگی، شبکه عصبی، الگوریتم بازشناسی الگو، الگوریتم کلونی مورچگان.

۱. استاد دانشکده مدیریت و حسابداری، پردیس فارابی، دانشگاه تهران، قم، ایران. jandaghi@ut.ac.ir

۲. استادیار دانشکده مدیریت و حسابداری، پردیس فارابی، دانشگاه تهران، قم، ایران (نویسنده مسئول). alisananj@ut.ac.ir

۳. دکتری مدیریت مالی، دانشکده مدیریت و حسابداری، پردیس فارابی، دانشگاه تهران، قم، ایران. r.rajaei@ut.ac.ir

۴. استادیار دانشکده مدیریت و حسابداری، پردیس فارابی، دانشگاه تهران، قم، ایران. ghasemiamhad@ut.ac.ir

۵. استاد گروه مدیریت مالی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران. rtehrani@ut.ac.ir

ریسک اعتباری مالی نشان‌دهنده میزان زیان ناشی از قصور وام‌گیرنده است که یا قادر به پرداخت دیون به وام‌دهندگان نیست یا اعلام ورشکستگی می‌کند (Antunes *et al.*, 2017). به عبارت دیگر، بیانگر وضعیت بالقوه یک وام‌گیرنده، در بازپرداخت نکردن دیون و تعهدهای مالی است (Liu *et al.*, 2019). هدف مدیریت ریسک اعتباری بیشینه کردن بازگشت اعتبارهای داده‌شده با پذیرش میزان قابل‌قبولی از ریسک است (Fernandes & Artes, 2016). ریسک اعتباری، از بااهمیت‌ترین ریسک‌ها در بانک‌ها و موسسه‌های مالی محسوب می‌شود. برای موسسه‌های مالی و بانک‌ها بسیار مهم است که سیستم‌های هشداردهنده دقیق‌تری در اختیار داشته باشند که بتوانند ورشکستگی را پیش از وقوع پیش‌بینی کنند (Wang *et al.*, 2017). بحران جهانی سال ۲۰۰۸ موجب می‌شود که بانک‌ها در بهبود مدل‌های مدیریت ریسک اعتباری، پریشانی مالی، و ورشکستگی تلاش بیش‌تری کنند (García *et al.*, 2019). در توافق بازل^۱ به منظور دستیابی به کفایت سرمایه لازم برای بانک‌ها، به‌صراحت مسئولیت مدیریت ریسک اعتباری درونی به آن‌ها محول می‌شود. با مدیریت اثربخش ریسک اعتباری، بانک‌ها علاوه بر حمایت از دوام و سودآوری کسب‌وکارشان، باعث تداوم منظم در تخصیص کارای سرمایه در اقتصاد می‌شوند (Psillaki *et al.*, 2010). وقوع ریسک اعتباری نه‌تنها سودآوری بانک‌ها، شرکت‌ها، و مشتریان را خدشه‌دار می‌کند، بلکه در مقیاسی وسیع‌تر باعث پدید آمدن خسران اقتصادی می‌شود (Liu *et al.*, 2019). برای موسسه‌های مالی و اعتباری و بانک‌ها، موضوع بهبود و مدیریت روابط با مشتریان در ایجاد روابط بلندمدت و پایدار مهم است (قره‌پاشا و همکاران، ۱۳۹۷). مدیریت ریسک اعتباری برای بانک‌ها یک ضرورت است و حفظ کارایی در ریسک اعتباری از اجزای مهم روش جامع مدیریت ریسک است و جزو الزام‌های لازم برای موفقیت بلندمدت هر بانک محسوب

۱. عالی‌ترین نهاد بین‌المللی در نظارت بانکی، کمیته بال (بازل) است. این کمیته مرکب از نمایندگان ارشد بانک‌های مرکزی تعدادی از کشورهای عمده صنعتی دنیاست. از مهم‌ترین اقدام‌های کمیته بال تهیه و انتشار اصول پایه در نظارت بانکی کارا و موثر، و همچنین مقررات مربوط به کفایت سرمایه است. از آن‌جا که تضمین نگهداری وجوه و منابع سرمایه‌ای معتبر موجب کاهش ریسک سپرده‌گذاران بانک‌ها می‌گردد، یکی از شاخص‌های مهم ارزیابی بانک‌ها نسبت کفایت سرمایه است. این نسبت اولین بار در سال ۱۹۸۸ توسط کمیته بال به بانک‌های دنیا معرفی گردید. کمیته بال در آن سال مجموعه‌ای از شروط حداقل سرمایه را به بانک‌ها پیشنهاد کرد که بعدها به عنوان «توافق بازل» معروف شد.

می‌شود. کارایی با حفظ منابع سازمان رابطه مستقیم دارد و ایجاد نظام کارا و مصرف بهینه منابع از ویژگی‌های مهم سازمانی است که می‌تواند منابع مالی را حفظ کند (خلیلی و علی‌نژاد، ۱۳۹۵). روش‌های مختلفی بر پایه ریاضی و آمار برای ارزیابی ریسک اعتباری پیشنهاد می‌شود. این روش‌ها بیش‌تر به وسیله عوامل بیرونی، احتمال ورشکستگی را تخمین می‌زنند (Fernandes & Artes, 2016). بنابراین، ارزیابی ریسک اعتباری برای کنترل ریسک ضروری است و لازمه آن وجود یک سیستم علمی توانمند و دقیق است که بتواند تعهد و قابلیت بازپرداخت وام‌گیرنده را بسنجد. ارزیابی ریسک اعتباری نه‌تنها می‌تواند احتمال ورشکستگی را زودتر تشخیص دهد و تصمیم‌های متناسب با آن را اتخاذ کند، بلکه می‌تواند پورتفوی سرمایه‌گذاری وام‌دهنده را بهینه کند (بدین معنا که ریسک و بازده را متعادل کند). بنابراین ارزیابی اعتباری، جذابیت بسیاری میان پژوهشگران به‌دست آورده است (Djebali & Zaghdoudi, 2020; Fanelli & Maddalena, 2020). لازمه ارزیابی صحیح ریسک اعتباری، وجود ابزارهای تحلیلی دقیق است که قادر به پیش‌بینی ورشکستگی شرکت‌ها باشند و بتوانند با دقت بالا، شرکت‌های مستعد ورشکستگی را از میان سایر شرکت‌ها تشخیص دهند (Antunes et al., 2017).

ورشکستگی زمانی رخ می‌دهد که یک شرکت یا شخص قادر به انجام تعهدهای مالی خود نباشد (Antunes et al., 2017). پیش‌بینی ورشکستگی شرکت یک مسئله مهم در حوزه مدیریت تصمیم است و هدف اصلی آن ایجاد تمایز بین شرکت‌های سالمی که احتمال ورشکسته شدن آنان در آینده زیاد است با شرکت‌های سالمی که این احتمال برای آن‌ها اندک است (Wang et al., 2014). تصمیم‌گیری نادرست موسسه‌های مالی ممکن است به مشکلات مالی یا درماندگی مالی منجر شود و این تاثیر بالا و هزینه‌های اجتماعی آن بر مالکان یا سهامداران، مدیران، و دولت باعث می‌شود که موضوع ریسک اعتباری جذابیت زیادی در میان پژوهشگران داشته باشد (Wang et al., 2014; Antunes et al., 2017; Liang et al., 2016; Jabeur, 2017). ورشکستگی شرکت‌ها که اغلب به‌طور غیرمنتظره رخ می‌دهد، نه‌تنها وجه مثبت شرکت‌ها را تحت تاثیر قرار می‌دهد و نشانه‌ای از ضعف مدیریتی است (محسنی و رحیمیان، ۱۳۹۷)، بلکه باعث رغبت سهامداران به خروج از شرکت می‌شود و در نتیجه بر رشد اقتصادی اثر می‌گذارد. برای کاهش اثرهای موارد اشاره‌شده، پیش‌بینی ورشکستگی مهم خواهد بود (Chou et al., 2017). پیش‌بینی ورشکستگی به دلیل اهمیت آن برای بخش بانکداری یک موضوع گسترده است. به همین دلیل، سرمایه‌گذاری بر مدل‌های پیش‌بینی ورشکستگی پیشرفته به نفع بانک‌ها و مشتریان است، چرا که پیش‌بینی‌های بهتر باعث کاهش ریسک می‌شوند. شرایط ورشکستگی مالی، وجود

یک شرکت را تحت تاثیر قرار می‌دهد و در صورتی که شرکت قادر به بازپرداخت بخشی از تسهیلات اعطایی یا کل آن نباشد، بانک و سایر مراکز اعتباری را در ریسک بازپرداخت نکردن دیون قرار می‌دهد. تاثیر نرخ بالای شکست تجاری می‌تواند برای مالک شرکت، شرکا، جامعه، و اقتصاد کشور در مقیاس بزرگ ویران‌کننده باشد. بنابراین، انجام پژوهش‌های گسترده در توسعه مدل‌های پیش‌بینی ورشکستگی برای شرکت‌ها بدون شک مهم است (Alaka et al., 2018). در سال‌های اخیر پژوهش‌های زیادی در زمینه عوامل موثر بر تداوم بانک‌ها صورت گرفته است (Djebali & Zaghdoudi, 2020; Fanelli & Maddalena, 2020; Veganzones & Séverin, 2018) و به‌طور خاص، ریسک اعتباری به عنوان بزرگ‌ترین ریسکی که می‌تواند در تداوم بانک تعیین‌کننده باشد، مورد توجه قرار گرفته است (Djebali & Zaghdoudi, 2020).

در پژوهش‌های حوزه ریسک اعتباری یک خلاء در ادبیات وجود دارد و آن، توجه کم به موضوع متغیرهای ورودی به عنوان بخشی از عملیات ارائه مدل ریسک اعتباری است. بسیاری از پژوهش‌ها با هدف ارائه تکنیک‌های جدید یادگیری ماشین انجام می‌شوند که عملکرد مدل‌های پیش‌بینی را افزایش می‌دهد، با این حال تعداد بسیار اندکی از پژوهشگران این حوزه، تاثیر متغیرهای ورودی (یا ویژگی‌ها) را بر عملکرد پیش‌بینی بررسی می‌کنند (Son et al., 2019; Volkov et al., 2017). در حالی که طبق گفته چو و همکاران (۲۰۱۷)، انتخاب متغیرهای ورودی و طبقه‌بندی دو بخش اصلی از یک مدل مالی ریسک اعتباری هستند. توباک و همکاران^۱ (۲۰۱۷)، به شکاف موجود اشاره می‌کنند و تمرکز پژوهش‌های حوزه نوآوری در مدل‌های طبقه‌بندی و غفلت از نوآوری را در ویژگی‌ها مورد نقد قرار می‌دهند. به‌طور کلی، نسبت‌های مالی به عنوان مهم‌ترین عوامل موثر در پیش‌بینی ورشکستگی شناخته می‌شوند، و به‌طور گسترده در مدل‌های پیش‌بینی ورشکستگی توسط پژوهشگران مورد استفاده قرار می‌گیرند (Liang et al., 2016).

نسبت‌های مالی را می‌توان در دسته‌های مختلف شامل نسبت‌های بدهی، سودآوری، نسبت‌های جریان نقدی، نسبت‌های ساختار سرمایه، نسبت‌های گردش مالی، و رشد طبقه‌بندی کرد. در عمده پژوهش‌ها، پژوهشگران متغیرهای ورودی را بر اساس توصیه سایر پژوهشگران یا از ادبیات استخراج می‌کنند (Barboza et al., 2017; Pompe & Bilderbeek, 2005; Berg, 2007; Gepp & Kumar, 2008) از آن‌ها به‌طور مستقیم در مدل خود استفاده می‌کنند. برخی دیگر از پژوهشگران نیز از روش‌های مبتنی بر آمار و ریاضی (kim et al., 2016; Nam & Jinn, 2000)، در انتخاب متغیرهای ورودی موثرتر استفاده می‌کنند. در حالی که اندکی از پژوهش‌ها (Chou et al., 2017; Liang et al., 2016; Wang et al.)

1. Tobback et al.

انتخاب می‌کنند. در موضوع مدل‌سازی ریسک اعتباری، تکنیک‌های هوش محاسباتی عملکرد مناسب‌تری نسبت به تکنیک‌های مبتنی بر ریاضی و آمار دارند (Son et al., 2019; Mai et al., 2019).
 در پژوهش حاضر، برای انتخاب عوامل موثرتر از الگوریتم کلونی مورچگان که از جمله الگوریتم‌های هوش محاسباتی است و طبقه‌بندی از طریق الگوریتم بازشناسی الگو که از الگوریتم‌های شبکه عصبی است، استفاده می‌شود. مدل نهایی با بکارگیری همزمان دو روش هوش محاسباتی به دست می‌آید. لازمه بکارگیری شبکه عصبی، وجود داده‌های لازم برای گروه آموزش و نمونه است. پس در پژوهش حاضر برای تأمین داده‌های مورد نیاز بازه زمانی ۲۶ ساله (۱۳۷۰-۱۳۹۵) لحاظ می‌شود.

در ادامه، مبانی نظری و پیشینه پژوهش مورد بحث قرار می‌گیرد و روش‌شناسی پژوهش شامل روش‌های الگوریتم کلونی مورچگان و الگوریتم بازشناسی الگو، معرفی می‌شود. در بخش بعدی، پنج متغیر (نسبت) انتخاب شده که خروجی الگوریتم مورچگان است گزارش می‌شود و با پنج متغیر انتخاب شده طبقه‌بندی انجام و دقت آن سنجیده می‌شود. در نهایت، نتیجه‌گیری متناسب با خروجی‌های به دست آمده بحث و تفسیر می‌شود.

مبانی نظری پژوهش

پیش‌بینی ورشکستگی از مسائل مهم علوم مالی و مدیریت است، که همیشه توجه پژوهشگران را به خود جلب می‌کند (Qu et al., 2019). با توسعه فناوری اطلاعات مدرن، زمینه برای استفاده از روش‌های یادگیری ماشین یا الگوریتم‌های یادگیری عمیق برای انجام پیش‌بینی از تحلیل اولیه صورت‌های مالی فراهم می‌شود. ارزیابی ریسک ورشکستگی تلاش می‌کند که با توجه به وضعیت کنونی یک شرکت، احتمال این که چنین شرکتی در آینده در شرایط ورشکستگی قرار بگیرد، پیش‌بینی کند. برای موسسه‌های مالی و اداره‌های دولتی، دانستن وجود تهدیدی قریب‌الوقوع که در اثر ورشکستگی می‌تواند به وجود بیاید، بسیار کلیدی است (Zoričák et al., 2020).

پیامدهای منفی بحران اقتصادی جهانی که اقتصاد کشورهای مختلف را تحت تأثیر قرار می‌دهد، نقش اساسی پیش‌بینی ورشکستگی را برجسته‌تر می‌کند (Boratyńska & Grzegorzewska, 2018). امور مالی و حسابداری حوزه‌های پیچیده‌ای هستند که در آن مولفه‌های چندگانه اغلب با یکدیگر تعامل دارند و پژوهش‌های گسترده‌ای برای کشف چالش‌های ناشی از این پیچیدگی‌ها توسط پژوهشگران انجام می‌شود. علاوه بر این، چالش ارزیابی دقیق پیش‌بینی شکست تجاری تحت سناریوی بحران

مالی پیچیده تلقی می‌شود. یک متغیر مداخله‌گر خاص در این پژوهش‌ها، نوسان بازار و پیش‌بینی ناپذیر بودن بازارهایی است که بیانگر نااطمینانی است. در چنین سناریوهایی، ریسک اعتباری از نگرانی‌های اصلی بانک‌ها و سرمایه‌گذارانی است که شرکت‌ها را بررسی و بر وضعیت مالی آن‌ها نظارت می‌کنند (Antunes et al., 2017). عملکرد مدل‌های پیش‌بینی ورشکستگی تا حد زیادی وابسته به انتخاب ابزاری است که ورشکستگی بر اساس آن بررسی می‌شود (Alaka et al., 2018).

پیش‌بینی ورشکستگی، که با عنوانی مانند پیش‌بینی ورشکستگی سازمانی یا پیش‌بینی شکست شرکت نیز شناخته می‌شود (Qu et al., 2019)، موضوع مهمی در زمینه حسابداری و امور مالی است، زیرا سلامت یک شرکت برای اعتباردهندگان، سرمایه‌گذاران، سهامداران، شرکا، و حتی خریداران و تامین‌کنندگان آن بسیار مهم است. بحران مالی جهانی سال ۲۰۰۸-۲۰۱۰ نشان می‌دهد شرکت‌هایی که درگیر روابط تجاری پیچیده هستند، آسیب‌پذیری بیش‌تری دارند که این رابطه پیچیده شامل رابطه آنها با موسسه‌های مالی و تعهداتشان به بخش‌های مالیاتی نیز می‌شود (Zoričák et al., 2020). تهدید ناشی از نامالیامات تجاری با پیچیده‌تر شدن اقتصاد افزایش می‌یابد. وضعیت بسیاری از شرکت‌ها بعد از بحران، گویای وضعیت شکننده ثبات مالی در آن‌هاست. این موضوع که این شرکت‌ها در معرض آشفتگی‌های مالی محیط خارجی دچار شوک مالی می‌شوند، ثابت است.

مدل‌ها و شاخص‌های ریسک اعتباری

انتخاب بین الگوریتم‌های یادگیری کار دشواری است و اغلب با توجه به در دسترس بودن یا شناخته شده بودن روش استفاده‌کننده، صورت می‌پذیرد (Sousa et al., 2016). شمار الگوریتم‌های یادگیری بالاست. بسیاری از چارچوب‌ها و تطابق‌ها با مسائل دنیای واقعی، و همچنین روش‌هایی که با بکارگیری توامان الگوریتم‌ها همراه هستند، استفاده و پیشنهاد می‌شوند و همچنان نیز پیشنهاد آن در ادبیات از نگرش‌های آماری تا الگوریتم‌های ماشین یادگیری، از مدل‌های پارامتریک تا مدل‌های ناپارامتریک ادامه دارد. به‌تازگی، روش‌های مبتنی بر یادگیری ماشین و اطلاعات محاسباتی به‌طور گسترده برای حل مشکل پیش‌بینی ورشکستگی پیشنهاد می‌شود (Chen et al., 2020). در دو دهه گذشته، تمایل به استفاده از روش‌های آماری، جای خود را به روش‌های هوشمند داده است، زیرا روش‌های هوشمند قادرند تعداد زیادی از ویژگی‌ها را در نظر بگیرند و روابط پیچیده‌تر بین آن‌ها را ارزیابی کنند (Zoričák et al., 2020). با وجود تنوع روزافزون روش‌های هوشمند، چهار تکنیک شبکه عصبی، درخت تصمیم، ماشین بردار

پشتیبان، و استدلال مورد محور در ارزیابی متغیرها با استفاده از داده‌ها بیش‌ترین استفاده را دارند (Wang et al., 2014). در یک دسته‌بندی کلی مدل‌های رایج ریسک اعتباری این‌گونه دسته‌بندی می‌شوند:

تحلیل ممیزی چندگانه (MDA):^۱ تحلیل ممیزی چندگانه از یک ترکیب خطی از متغیرها، به‌طور معمول از نسبت‌های مالی استفاده می‌کند و به دنبال یافتن بهترین وجه تمایز بین شرکت‌های ناموفق و موفق است و شرکت‌ها را به یکی از این دو گروه تقسیم می‌کند.

رگرسیون لجستیک (LR):^۲ مدل احتمال شرطی است که از تکنیک بیشینه‌لگاریتم - احتمال برای تخمین احتمال شکست شرکت استفاده می‌کند. در این مدل، فرض می‌شود که احتمال بازپرداخت نکردن از تابع توزیع لجستیک پیروی می‌نماید که بنابر تعریف، مقادیری بین صفر و یک را برمی‌گزیند. شبکه عصبی مصنوعی (ANN):^۳ از نحوه عملکرد سیستم عصبی مغز انسان برای تقلید ایجاد شد و نخستین بار در سال ۱۹۹۰ برای پیش‌بینی ورشکستگی بکار گرفته شد. شبکه عصبی مانند «جعبه سیاه» عمل می‌کند و در شرایطی که استخراج قوانین استنتاجی حاکم بر پدیده (مانند احتمال نکول یک شرکت)، سخت یا ناممکن باشد، می‌تواند مفید واقع شود.

ماشین بردار پشتیبان (SVM):^۴ یک طبقه‌بندی‌کننده دووجهی است. در این روش در مورد دو طبقه ابرصفحه‌ای ایجاد می‌شود و مدل می‌کوشد فاصله هر طبقه تا ابرصفحه بیشینه شود. اطلاعات نقطه‌ای که کم‌ترین فاصله را با ابرصفحه دارد، مبنای اندازه‌گیری است. این الگوریتم در دسته الگوریتم‌های بازشناسی الگوست و در مواقعی که نیاز به تشخیص الگو یا طبقه‌بندی موضوع‌ها وجود داشته باشد، بکار می‌رود.

مجموعه‌های راف (RS):^۵ فرض مدل بر این است که اطلاعات مربوط به تمام اشیا (شرکت‌ها در موضوع ورشکستگی)، در یک محیط حل مسئله خاص وجود دارد و این اطلاعات توسط برخی از ویژگی‌ها (متغیرها) می‌تواند اشیا (شرکت‌ها) را توصیف کند.

نزدیک‌ترین K همسایگی (KNN):^۶ یکی از روش‌های طبقه‌بندی غیرپارامتری است. در این الگوریتم، یک کلاس (طبقه) با توجه به متداول‌ترین کلاس در میان نزدیک‌ترین همسایه آن تخصیص داده می‌شود.

1. Multiple Discriminant Analysis
2. Logistic Regression
3. Artificial Neural Network
4. Support Vector Machines
5. Rough Sets
6. k-Nearest Neighbor

استدلال مورد محور (CBR)^۱: برخلاف مدل‌های مشابه یادگیری ماشینی به دنبال یافتن الگو نیست، بلکه راه‌حل را بر اساس شباهت مورد به موارد مشابه پیشین پیدا می‌کند. درخت تصمیم (DT)^۲: برای طبقه‌بندی شرکت‌ها از آنتروپی برای اندازه‌گیری قدرت متمایزکنندگی متغیرها استفاده می‌کند.

الگوریتم ژنتیک (GA)^۳: الگوریتم ژنتیک روشی برای بهینه‌سازی است که با الهام از اصل بقای شایسته‌ترین موجودات زنده عمل می‌کند. در این الگوریتم، اعضای شایسته یک نسل برای ایجاد نسلی از اعضای به‌احتمال شایسته‌تر ترکیب می‌شوند.

به دلیل دیدگاه مالی که حاکم بر وضعیت ورشکستگی شرکت‌ها قرار دارد، فرض عمومی فرایندهای پیش‌بینی ورشکستگی این است که عوامل اقتصادی و ویژگی شرکت در صورت‌های مالی منعکس می‌شوند (Chou *et al.*, 2017). در ادبیات، شاخص‌های متعددی برای بررسی ریسک اعتباری پیشنهاد می‌شود و مورد بررسی قرار می‌گیرد. این شاخص‌ها گاه از مجموعه نسبت‌های شناخته‌شده‌تر مانند نسبت‌های سودآوری، نقدینگی، و اهرمی استخراج می‌شوند و گاه مانند نسبت‌های فراتر از نسبت‌های اشاره‌شده یا ترکیبی از هر دو هستند. تعداد نسبت‌های مالی ارائه‌شده توسط کارشناسان مالی زیاد است و با این حال در مورد اهمیت برخی از نسبت‌های کلیدی‌تر در میان پژوهشگران اتفاق نظر وجود دارد. در جدول (۱)، نام برخی از این متغیرهای پرکاربردتر به همراه نام پژوهشگرانی که اهمیت آن‌ها تاکید می‌کنند یا آن‌ها را در برآورد ریسک اعتباری مورد استفاده قرار می‌دهند، آورده می‌شود.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

1. Case Based Reasoning
2. Decision Tree
3. Genetic Algorithm

جدول ۱: برخی متغیرهای پرکاربرد تر ریسک اعتباری

ردیف	متغیرها (نسبت‌ها)	استینوز و کاربالو ^۱ (۲۰۱۵)	هی و همکاران ^۲ (۲۰۱۶)	ژیونگ و همکاران ^۳ (۲۰۱۳)	سوارز و همکاران ^۴ (۲۰۱۱)	پسیلاکی و همکاران ^۵ (۲۰۱۰)	سیرونی و رستی ^۶ (۲۰۰۷)	پیراموثو ^۵ (۱۹۹۹)	گرونرت و همکاران ^۶ (۲۰۰۵)
۱	فروش به کل دارایی				x			x	x
۲	EBIT به کل دارایی				x	x		x	
۳	EBIT به فروش کل	x			x		x	x	
۴	سود ناخالص به فروش کل		x				x		
۵	کل بدهی به کل دارایی		x	x		x		x	
۶	کل حقوق صاحبان سهام به کل بدهی		x	x		x		x	
۷	بدهی‌های جاری به کل بدهی‌ها								x
۸	سرمایه در گردش به کل دارایی‌ها					x		x	
۹	نسبت جاری			x	x	x		x	x
۱۰	نسبت آنی			x					x
۱۱	نسبت وجه نقد			x				x	
۱۲	حاشیه سود خالص			x					x
۱۳	بازده حقوق صاحبان سهام			x	x	x		x	x
۱۴	بازده دارایی‌ها ROA			x	x	x		x	x
۱۵	بازده سرمایه در گردش				x				
۱۶	بازده دارایی ثابت			x	x	x			
۱۷	نسبت دارایی‌های جاری			x					

1. Estévez & Carballo
2. He *et al.*
3. Soares *et al.*
4. Sironi & Resti
5. Piramuthu
6. Grunert *et al.*

ادامه جدول ۱: برخی متغیرهای پر کاربرد تر ریسک اعتباری

پژوهشگران		متغیرها (نسبت‌ها)	ردیف
گروت و همکاران (۲۰۰۵)		دوره وصول مطالبات	۱۸
پیرامیتو (۱۹۹۹)		نسبت کالا به سرمایه در گردش	۱۹
سیرونی و رستی (۲۰۰۷)		گردش دارایی‌های ثابت	۲۰
پسیلاکی و همکاران (۲۰۱۰)		بدهی کل به EBIT	۲۱
سوازی و همکاران (۲۰۱۱)		EBIT به هزینه‌های مالی	۲۲
ژبوتگ و همکاران (۲۰۱۳)		حاشیه سود اقتصادی	۲۳
هی و همکاران (۲۰۱۶)		نرخ رشد سود قبل از مالیات به فروش	۲۴
استنوز و کاربالو (۲۰۱۵)		نرخ رشد سود قبل از کسر مالیات	۲۵
		سودآوری پروژه سرمایه‌گذاری شده	۲۶
		نسبت بدهی به حقوق صاحبان سهام	۲۷
		رشد نسبت بدهی کوتاه به بلندمدت	۲۸
		نرخ رشد سود خالص	۲۹
		جایگاه در صنعت	۳۰
		نرخ رشد دارایی کل	۳۱

انتخاب ویژگی

هدف از پیش‌بینی ورشکستگی، ارزیابی شرایط مالی یک شرکت و وضعیت آتی آن در زمینه عملکرد بلندمدت در بازار است. لازمه این مهم، استفاده از ترکیب منابع مالی و اقتصادی است که

دانش کارشناسی در مورد پدیده و داده‌های تاریخی شرکت‌های موفق و ناموفق را با هم ترکیب می‌کند. به‌طور معمول، وضعیت شرکت‌ها با استفاده از تعداد زیادی از شاخص‌هایی که شرایط کسب‌وکار خود را توصیف می‌کنند تعیین می‌شود، که این داده‌ها بیش‌تر برای ایجاد یک مدل ریاضی با استفاده از مشاهده‌های پیشین تولید می‌شوند (Zięba *et al.*, 2016). انتخاب نسبت مالی در پیش‌بینی ورشکستگی مشابه استخراج ویژگی در روش بازشناسی الگوست. استخراج نسبت‌های مالی کلیدی از صورت‌های مالی به شیوه‌های مختلف انجام می‌شود (Du Jardin, 2016). در ادبیات مربوط به ورشکستگی برای به‌دست آوردن مجموعه نسبت‌های مناسب، از روش‌های مبتنی بر ریاضی و غیرمبتنی بر ریاضی استفاده می‌شود. در رویکرد غیرمبتنی بر ریاضی، نسبت‌های مالی بر اساس پیشنهادهای پژوهش‌های پیشین یا بر اساس توصیه متخصصان مالی انتخاب می‌شوند. برای روش ریاضی، تکنیک‌های آماری و تکنیک‌های هوش محاسباتی به‌طور گسترده مورد استفاده قرار می‌گیرد. برای رویکرد آماری، شاخص‌های اندازه‌گیری همچون آمار جدول متقاطع، آمار آزمون کای اسکوئر، و نقدینگی استاندارد برای انتخاب نسبت بکار گرفته می‌شود. استفاده از انواع تکنیک‌های هوشمند، به‌ویژه محاسبه نرم پیش‌بینی ورشکستگی، در طول دهه گذشته به‌طور قابل توجهی افزایش یافته است. تکنیک‌های هوشمند برای انتخاب نسبت عبارت‌اند از تحلیل مولفه‌های اصلی، درخت تصمیم‌گیری، الگوریتم ژنتیک، شبکه عصبی، و بهینه‌سازی ازدحام ذرات (Chou *et al.*, 2017).

مدل‌های پیش‌بینی (طبقه‌بندی‌کننده)

ورشکستگی شرکتی یکی از محورهای اصلی ریسک اعتباری محسوب می‌شود و به‌طور ویژه بسیار مورد توجه اعتباردهندگان و سرمایه‌گذاران است (Mai *et al.*, 2019). آسیب مالی که در اثر ورشکستگی شرکت‌ها می‌تواند بر پیکر اقتصاد کشور وارد شود، بسیار قابل توجه است. بحران مالی سال ۲۰۰۸-۲۰۱۰ نشان می‌دهد که ورشکستگی شرکت‌ها اثر منفی عمیقی بر اقتصاد می‌گذارد. ورشکستگی شرکتی می‌تواند به ایجاد یک هزینه اجتماعی منفی منجر شود که به دنبال آن رکود اقتصادی تشدید می‌شود و در نتیجه اقتصاد را به‌طور جدی به خطر می‌اندازد. بنابراین، یک مدل پیش‌بینی ورشکستگی دقیق برای بازیگران تجاری، قانونگذاران، و پژوهشگران بسیار ارزشمند است. قانونگذار با چنین مدلی می‌تواند بر سلامت مالی موسسه‌ها و جلوگیری از ریسک‌های سیستمی آن‌ها نظارت داشته باشد. بازیگران تجاری می‌توانند با استفاده از آن بدهی شرکت را برای رتبه‌بندی داخلی قیمتگذاری کنند. پژوهشگران نیز می‌توانند با استفاده از خروجی نتایج چنین مدلی به تنظیم مدل‌های نظری مختلف بپردازند. به این دلایل، پژوهشگران این پژوهش به دنبال

مدل‌های پیش‌بینی موثرتر برای پیش‌بینی ورشکستگی و بحران مالی هستند. مشخصه اصلی موفقیت یک مدل پیش‌بینی ورشکستگی این است که مدل قادر باشد با استفاده از مجموع متغیرها میان شرکت‌هایی با احتمال بالاتر ورشکستگی با سایر شرکت‌ها تمایز ایجاد کند (Lyandres & Zhdanov, 2013). توسعه یک مدل پیش‌بینی ورشکستگی موثر، برای موسسه‌های مالی کار بسیار مهم و دشواری است. مدل‌های پیش‌بینی ورشکستگی پیش‌بینی می‌کنند که آیا متقاضی جدید (شامل افراد و شرکت) در آینده ورشکسته می‌شود یا خیر. اگر مدل‌های پیش‌بینی به خوبی عمل نکنند و نرخ خطای پیش‌بینی آن‌ها بالا باشد، استفاده از آن‌ها باعث اتخاذ تصمیم‌های نادرست می‌شود و در نتیجه به احتمال زیاد، بحران‌های مالی بزرگی رخ خواهد داد. مشابه با هدف پیش‌بینی ورشکستگی، امتیازدهی یا رتبه‌بندی اعتباری برای تعیین این‌که آیا مشتریان وام به یک گروه خوب یا بد (از نظر اعتباری) تعلق دارند، مورد استفاده قرار می‌گیرد. به عبارت دیگر، یک مدل نمره‌دهی اعتباری موثر می‌تواند به ایجاد یک دستورالعمل مالی کمک کند که تصمیم بگیرد به متقاضیان جدید اعتباری وام تعلق بگیرد یا خیر. به‌طور ویژه، مدل پیش‌بینی ورشکستگی و امتیازهای اعتباری هر دو به عنوان مسئله تصمیم‌گیری مالی و به عنوان مسائل طبقه‌بندی دوگانه شناخته می‌شوند (Tsai *et al.*, 2014). یعنی مدل طراحی شده در آن‌ها برای تعیین مشاهده‌های جدید و طبقه‌بندی آن‌ها به دو گروه از پیش تعیین شده «مناسب» یا «نامناسب» بکار می‌رود. به عبارت دیگر، اگر یک مدل امتیازدهی مالی مشاهده جدیدی را به طبقه «نامناسب» طبقه‌بندی کند، شبیه به این است که پیش‌بینی ورشکستگی آن را ورشکسته محسوب کند. به عبارت دیگر، ریسک «نامناسب» می‌تواند به‌سادگی به عنوان «ورشکستگی» تلقی شود.

برای بررسی عملکرد مدل‌های پیش‌بینی، به‌طور معمول دو معیار ارزیابی در نظر گرفته می‌شود، که میانگین پیش‌بینی میانگین و خطای نوع ۱ هستند (Liang *et al.*, 2016). میانگین دقت پیش‌بینی این‌گونه محاسبه می‌شود که به چه میزانی، نمونه‌ها به‌درستی با مدل پیش‌بینی روی یک مجموعه آزمون مشخص طبقه‌بندی می‌شوند. خطای نوع ۱ معیاری است از تعداد نمونه‌های داده که در آن مدل پیش‌بینی به‌طور نادرستی یک شرکت غیرورشکسته را در طبقه ورشکسته طبقه‌بندی می‌کند. معیار خطای نوع ۱ گاهی می‌تواند نسبت به معیار دقت پیش‌بینی میانگین بسیار مهم‌تر و اساسی‌تر باشد. همچنان‌که هیچ نظریه برتری نسبت به ورشکستگی شرکت‌ها وجود ندارد، بیش‌تر پژوهش‌ها در ورشکستگی شرکت‌ها مبتنی بر فرایندهای تکرار و خطا در انتخاب ویژگی‌ها و مدل‌های پیش‌بینی است. با توسعه آمار و هوش مصنوعی، برخی از روش‌های آماری و روش‌های هوشمند برای پیش‌بینی ورشکستگی شرکت‌ها پیشنهاد می‌شود. روش‌های آماری

که در پیش‌بینی ورشکستگی سازمانی بکار گرفته می‌شوند عبارت‌اند از تحلیل ممیزی خطی، تحلیل ممیزی چندمتغیره، تحلیل ممیزی درجه دوم، تحلیل رگرسیون لجستیک، و تحلیل عاملی. با این حال، مشکل استفاده از این تکنیک‌های آماری برای پیش‌بینی ورشکستگی سازمانی این است که برخی از فرض‌ها، مانند فرض‌های نرمال چندمتغیره برای متغیرهای مستقل، بیش‌تر اوقات در عمل نقض می‌شوند، که باعث می‌شود روش‌های اشاره‌شده برای نمونه‌های محدود از لحاظ نظری نامعتبر شوند. برخلاف تکنیک‌های آماری که فرض می‌کنند امکان گرفتن خروجی و نتیجه با داده‌های نمونه‌ای وجود دارد، تکنیک‌های هوشمند بر مبنای چنین فرضی استوار نیستند. با این حال، هیچ‌کدام از روش‌های هوشمند پیش‌بینی به عنوان بهترین روش در پیش‌بینی ورشکستگی شرکت‌ها شناخته نمی‌شود. عملکرد پیش‌بینی روش‌ها به جزییات مسئله، ساختار داده‌ها، ویژگی‌های مورد استفاده، و میزان امکان جداسازی کلاس‌ها با استفاده از آن ویژگی‌ها، بستگی دارد. به‌تازگی، ادغام چندین پیش‌بینی‌کننده در یک خروجی جمعی یا روش‌های گروهی، به عنوان یک راهبرد کارآمد برای دستیابی به عملکرد پیش‌بینی بالا مورد استفاده قرار می‌گیرد، به‌ویژه زمانی که پیش‌بینی‌های جزئی، ساختارهای متفاوتی دارند که به خطاهای پیش‌بینی مستقل منجر می‌شوند.

شبکه‌های عصبی

شبکه‌های عصبی (یا شبکه‌های عصبی مصنوعی)، شامل واحدهای پردازش اطلاعات و مشابه نورون‌های موجود در مغز انسان هستند، با این تفاوت که واحدهای پردازش اطلاعات در یک شبکه عصبی، مصنوعی هستند. شبکه‌های عصبی می‌توانند با استفاده از تجربه یاد بگیرند، از تجربه‌های قبلی به افراد جدید تعمیم یابند، و از این‌رو تصمیم‌های مفیدی اتخاذ کنند (Tsai et al., 2014). در مورد روش‌های پیش‌بینی ورشکستگی، مزیت عمده روش شبکه‌های عصبی، قابلیت یادگیرنده بودن آن است (ظهیری و افشارکاظمی، ۱۳۹۱). شبکه عصبی متشکل از گره‌های نورونی است که به گره‌های وزن‌دار متصل می‌شوند. گره‌ها و ارتباط در میان گره‌ها به‌ترتیب مشابه نورون‌های مغزی و سیناپس‌ها هستند که نورون‌های مغزی را به یکدیگر متصل می‌کنند. رایج‌ترین مدل شبکه عصبی، شبکه چندلایه است که شامل یک لایه ورودی با مجموعه‌ای از گره‌های حسی به عنوان گره‌های ورودی، یک یا چندلایه پنهان از گره‌های محاسبه‌کننده، و یک لایه خروجی از گره‌های محاسبه‌شده است. گره‌ها یا نورون‌های ورودی ارزش ویژگی یک نمونه هستند، در حالی که گره‌های خروجی متمایزکننده طبقه نمونه با طبقه سایر نمونه‌ها هستند.

الگوریتم‌های یادگیری ماشین نسبت به مدل‌های آماری برای پیش‌بینی ورشکستگی مناسب‌تر هستند (Son et al., 2019). به گفته سون و همکاران (۲۰۱۹)، روش‌های یادگیری ماشینی نظیر ماشین بردار پشتیبان و شبکه عصبی نسبت به روش‌های آماری سنتی از دقت بالاتری برخوردارند. چن و همکاران (۲۰۲۰)، و زوریکاک و همکاران (۲۰۲۰)، نیز از دقت بالاتر روش‌های هوش محاسباتی نسبت به روش‌های آماری سنتی و در نتیجه، تمایل بالاتر پژوهشگران در استفاده از این روش‌ها می‌گویند.

هدف از انجام پژوهش حاضر، شناسایی مهم‌ترین متغیرهای موثر در ریسک اعتباری و به علاوه طبقه‌بندی شرکت‌ها بر اساس عوامل شناسایی شده و بررسی میزان دقت پیش‌بینی مدل است. در این پژوهش، انتخاب ویژگی با استفاده از الگوریتم کلونی مورچگان و طبقه‌بندی با استفاده از الگوریتم بازشناسی الگوی شبکه عصبی انجام می‌شود. در مدل‌های قدیمی‌تر، مانند مدل درجه‌بندی بر اساس تحلیل ممیز خطی و مدل درجه‌بندی بر اساس رگرسیون لجستیک، وجه مشترکی وجود دارد و آن کوشش برای تعیین روابط بنیادینی است که تعادل مالی - اقتصادی یک شرکت را نشان می‌دهد که می‌تواند برای پیش‌بینی احتمال نکول بکار رود. به عبارت دیگر، این مدل‌ها بر اساس ویژگی‌های ساختاری هستند که وضعیت سلامت یک شرکت را توصیف می‌کند و انتخاب متغیرها، مرتبط با استفاده از سابقه تاثیرشان بر جنبه‌های اقتصادی است. به همین دلیل، مدل‌ها بر اساس نگرش ساختاری شکل می‌گیرند. به این ترتیب که توسط فرض یک تحلیلگر (برای مثال شرکتی که بیش از اندازه اقدام به استقراض می‌کند، در بازپرداخت تمام بدهی‌های خود ناتوان است) ایجاد می‌شود و سپس به دنبال تایید این فرض‌ها در داده‌های یک نمونه واقعی هستند. در مقابل، شبکه عصبی از یک فرایند صرفاً قیاسی استفاده می‌کند، به این شکل که اگر در داده‌های نمونه، قاعده تجربی خاصی یافت شود، این قاعده در پیش‌بینی نکول در آینده برای سایر شرکت‌ها مورد استفاده قرار می‌گیرد. بنابراین، برخلاف مدل‌های پیشین که بر اساس قواعد استنتاجی‌اند، در شبکه عصبی یک نگرش صرفاً تجربی مورد استفاده قرار می‌گیرد. مدل‌های ساختاری بر اساس الگوریتم‌های مشخص و اثبات شده هستند که برای آزمون‌های استنباطی در تایید اهمیت ضرایب تخمینی مورد استفاده قرار می‌گیرند. در مقابل، روش‌های مبتنی بر نگرش قیاسی مانند شبکه عصبی می‌توانند مانند یک جعبه سیاه عمل کنند و در شرایطی که استخراج قوانین استنتاجی حاکم بر یک پدیده (همچون احتمال نکول یک شرکت)، سخت یا ناممکن باشد، مفید واقع شوند.

الگوریتم کلونی مورچگان

ایده الگوریتم کلونی مورچه، تقلید این رفتار با مورچه‌های شبیه‌سازی شده‌ای است که در اطراف نمودار راه می‌روند، و موجب حل مسئله می‌شوند. مزیت آن نسبت به روش ژنتیک زمانی است که گراف ممکن است به صورت پویا تغییر کند، و در این حالت الگوریتم مورچگان می‌تواند به‌طور پیوسته اجرا و با تغییر در زمان واقعی سازگار شود. همچنین، الگوریتم مورچگان برای دیگر مسائل بهینه‌سازی از جمله شبکه‌های مخابراتی، داده‌کاوی، و مسیریابی خودرو بکار گرفته می‌شود. گام‌های اصلی این روش عبارتند از ۱. دادن مقادیر اولیه به پارامترهای کلونی مورچگان مانند تعداد نسل‌ها و فرومون اولیه؛ ۲. نمایش ویژگی‌ها به صورت گره‌های گراف، تولید تعدادی مورچه، و قرار دادن آن‌ها به صورت تصادفی روی گره که در این حالت هر مورچه با یک ویژگی تصادفی شروع می‌کند و سپس اقدام به محاسبه نیکی برآزش تمام مورچه‌ها می‌کند؛ ۳. همزمان اقدام به ایجاد راه‌حل توسط تمام مورچه‌های نماینده، به‌طوری که مورچه k م به‌طور تصادفی روی گره (ویژگی) i قرار داده می‌شود. مورچه k در گره i بعدی j را با احتمال فرمول (۱) انتخاب می‌کند.

$$P_k(i, j) = \begin{cases} \frac{[\tau_{ij}]^\alpha [\eta_{ij}]^\beta}{\sum_{u \in J_K(i)} [\tau_{iu}]^\alpha [\eta_{iu}]^\beta} & \text{if } j \in J_K(i) \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

که در این جا η_{ij} اطلاعات اکتشافی را نشان می‌دهد، $J_K(i)$ مجموعه‌ای از گره‌های همسایه گره i است که هنوز توسط مورچه k مورد بازدید قرار نگرفته است. α و β دو پارامتر هستند که اهمیت نسبی فرومون را با توجه به اطلاعات اکتشافی تعیین می‌کنند. اطلاعات اکتشافی از طریق فرمول (۲) به‌دست می‌آید.

$$\eta_{ij} = \frac{\sum_{n=1}^N x_{ni} x_{nj}}{\sqrt{\sum_{n=1}^N x_{ni} x_{nj}}} \quad (2)$$

N تعداد کل نمونه‌های آموزشی است. گره بعدی j به صورت فرمول (۳) اضافه می‌شود:

$$j = \begin{cases} \operatorname{argmax}_{u \in J_K(i)} \{[\tau_{iu}]^\alpha [\eta_{iu}]^\beta\} & \text{if } q \leq q_0 \\ J & \text{if } q > q_0 \end{cases} \quad (3)$$

به‌طوری که q عدد تصادفی یکنواخت در بازه صفر تا یک است، q_0 پارامتر آستانه است، $J \in J_K(i)$ گره است که به‌طور تصادفی با توجه به احتمال‌ها اضافه می‌شود. پس از انتخاب گره

بعدی، زیرمجموعه ویژگی جدید به دست می آید و محاسبه نیکوی برازش مورچه انجام می شود. اگر معیار توقف تامین شود، عبور متوقف می شود (معیار توقف می تواند تعداد معینی از ویژگی هایی باشد که انتخاب شده اند، یا مربع خطا در حالتی که پس از گنجاندن ویژگی جدید هیچ پیشرفتی حاصل نشود یا پیشرفت کم باشد، به طوری که کم تر از آستانه از پیش تعیین شده باشد).

۴. به روزرسانی فرمون در مسیرها. بعد از این که بهترین مورچه با کوچک ترین خطای مربع به عنوان راه حل بهینه جامع انتخاب می شود. در ادامه، به روزرسانی های جامع انجام می شود، تنها مورچه ای که بهترین راه حل را ایجاد می کند، سطح فرمون را در مسیر تقویت می کند که بخشی از راه حل بهینه است. این کار جستجو را در همسایگی بهترین راه حل هدایت می کند. به روزرسانی با فرمول (۴) و (۵) صورت می گیرد:

$$\rho \Delta \tau_{ij} + (1 - \rho) \tau_{ij} \rightarrow \tau_{ij} \quad (4)$$

$$\Delta \tau_{ij} = \begin{cases} \frac{Q}{J_{min}} & \text{if } \{ij\} \in S^+ \\ 0 & \text{if } \{ij\} \notin S^+ \end{cases} \quad (5)$$

$\rho (0 < \rho \leq 1)$ پارامتری است که تنزل فرمون را کنترل می کند.

۵. خاتمه عملیات در صورتی که وضعیت توقف حاصل شود، و در غیر این صورت، عملیات در گام دوم دوباره آغاز می شود. در صورتی که راه حل بهینه پیش فرض حاصل شود و در راه حل جامع، تغییرهای متوالی و اندک داشته باشد، عملیات متوقف می شود (معیار توقف حاصل می شود). در اواسط دهه ۱۹۸۰ میلادی بیش تر موسسه های مالی به تحلیل ضمنی دارایی ها در ارزیابی ریسک اعتباری وام شرکت ها با استفاده از خبرگان بانکی که از اطلاعاتی همچون شهرت، اهرم، تاریخ، و الگوی درآمد برخوردار بودند، برای اتخاذ تصمیم قضاوتی ضمنی بهتر استفاده می کردند. به طور طبیعی در گذر سال ها، بانک ها از این سیستم ها به سمت ضوابط عینی تر حرکت کردند. در طول ۵۰ سال گذشته، موضوع پیش بینی ورشکستگی توجه زیادی میان پژوهشگران به خود معطوف کرده است (Chen et al., 2020; Shi & li, 2019; Son et al., 2019). بسیاری از پژوهش ها به بررسی مدل پیش بینی ورشکستگی شرکت می پردازند و می کوشند پیش بینی را با دقت بهتری انجام دهند (Shi & li, 2019; Mai et al., 2019; Volkov et al., 2017; Kim et al., 2016). در اغلب موارد، نویسندگان تمایل دارند که از شکست (ورشکستگی)، به عنوان عامل ممیز بین شرکت های موفق و ناموفق استفاده کنند. در کنار توسعه علوم رایانه ای و فناوری هوش مصنوعی، برخی پژوهشگران از تکنیک های یادگیری ماشینی برای ساخت مدل های پیش بینی ورشکستگی استفاده می کنند

Chou et al., 2017; Liang et al., 2016; Wang et al., 2014; Chen et al., 2011) و برخی دیگر به‌طور خاص دو یا سه تکنیک یادگیری ماشین را برای مدلسازی پیش‌بینی ورشکستگی مقایسه می‌کنند (Shi & Li, 2019). با وجود شمار بالای این مدل‌ها یک توسعه‌دهنده مدل پیش‌بینی ورشکستگی باید قدرت و محدودیت‌های ابزار و تکنیک‌های موجود را از جنبه‌های مختلف شامل دقت و خطای نوع ۱ درک کند و متناسب با نوع پژوهش و داده‌ها، اقدام به استفاده از روش بهتر کند (Alaka et al., 2018). در جدول (۲)، خلاصه پژوهش‌ها آورده می‌شود.

جدول ۲: خلاصه برخی پژوهش‌های حوزه ریسک اعتباری

پژوهشگران (سال)	هدف	روش‌های مورد استفاده	نتایج
مای و همکاران (۲۰۱۹)	مدل‌های یادگیری عمیق برای پیش‌بینی ورشکستگی شرکت‌ها با استفاده از افشای متنی	مدل‌های یادگیری عمیق	عملکرد بهتر مدل‌های یادگیری عمیق برای پیش‌بینی ورشکستگی با استفاده از افشای متنی.
جابور (۲۰۱۷)	بالاتر بردن دقت مدل پیش‌بینی رگرسیون لجستیک از طریق لحاظ کردن طیف وسیع‌تر شاخص‌ها	مدل رگرسیون خطی حداقل مربع خطای بخشی (PLS-LR)	برآورد ورشکستگی با دقت ۹۳/۷ درصد.
زوریکاک و همکاران (۲۰۲۰)	ارائه روش شناسی برای اثربخشی یادگیری ماشینی در مورد پیش‌بینی ورشکستگی شرکت‌های کوچک و متوسط در حالت وجود داده‌های نامتقارن	روش حداقل مربع‌ها برای تشخیص ناهنجاری، جنگل انزوا، ماشین‌های بردار پشتیبان	ارائه تحلیل جامع ویژگی‌های مالی و تعیین موثرترین آن‌ها در پیش‌بینی ورشکستگی.
ایتوریاگا و سانز (۲۰۱۵)	توسعه مدل شبکه‌های عصبی با ترکیب روش شبکه عصبی خودسامانده و چندلایه برای بررسی ورشکستگی بانک‌های آمریکا در بحران مالی اخیر	شبکه عصبی خودسامانده و چندلایه	عملکرد بهتر نسبت به مدل‌های سنتی و قابلیت پیش‌بینی ورشکستگی با دقت بالای ۹۰ درصد.
دو جاردین (۲۰۱۵)	ارائه مدلی برای افزایش افق پیش‌بینی ورشکستگی از یک سال	شبکه عصبی، تحلیل ممیزی چندگانه، رگرسیون لجستیک	دقت بالاتر پیش‌بینی در افق سه‌ساله نسبت به مدل‌های مشابه.

ادامه جدول ۲: خلاصه برخی پژوهش‌های حوزه ریسک اعتباری

پژوهشگران (سال)	هدف	روش‌های مورد استفاده	نتایج
ویراگ و نیترای (۲۰۱۴)	تجزیه و تحلیل مقایسه‌ای از طریق داده‌کاوی و مقایسه نظریه مجموعه خام با دو روش شبکه‌های عصبی و ماشین‌های بردار پشتیبان	روش‌های داده‌کاوی، شبکه‌های عصبی، ماشین‌های بردار پشتیبان، نظریه مجموعه خام	روش‌های جعبه سیاه، مانند شبکه عصبی، طبقه‌بندی بهتر و قدرت پیش‌بینی بیش‌تری نسبت به روش‌های غیر جعبه سیاه دارند.
دیالی و زقدودی (۲۰۲۰)	بررسی روابط بین نقدینگی و ریسک‌های اعتباری بر ثبات بانکی در منطقه MENA	رگرسیون آستانه هموار (PSTR)	نیاز به اصلاح سیستم‌های مالی در منطقه MENA
هئو و یانگ ^۲ (۲۰۱۴)	برای نشان دادن مناسب بودن مدل AdaBoost (تقویت تطبیقی)، برای قضاوت در مورد ریسک مالی شرکت‌های ساختمانی	شبکه‌های عصبی، ماشین‌های بردار پشتیبان، درخت تصمیم، تحلیل ممیزی چندگانه	AdaBoos در مورد ریسک مالی شرکت‌های ساختمانی از سایر مدل‌ها بهتر عمل می‌کند.
گردینی ^۳ (۲۰۱۴)	مقایسه الگوریتم‌های ژنتیک با رگرسیون لجستیک و ماشین بردار پشتیبان در پیش‌بینی اعتباری شرکت‌های کوچک و متوسط	الگوریتم‌های ژنتیک، رگرسیون لجستیک، ماشین بردار پشتیبان	عملکرد بهتر الگوریتم‌های ژنتیک نسبت به رگرسیون لجستیک و ماشین بردار پشتیبان
لیو و همکاران (۲۰۱۹)	ارائه یک شاخص اعتبار خوشه‌بندی جدید برای مسئله ارزیابی ریسک اعتباری	استفاده از الگوریتم خوشه‌بندی چندهدفه Multi-Objective Soft Subspace Clustering (EMOSSC) Algorithm	عملکرد بهتر مدل پیشنهادی پژوهش نسبت به سایر مدل‌ها
برتاینزکا و گریگوروزوسکا (۲۰۱۸)	اجرای FSQCA برای پیش‌بینی ورشکستگی نهاده‌ای تجاری کشاورزی و مقایسه با روش‌های کمی کلاسیک	مدل‌های رگرسیون چندمتغیره شامل آنالیز افتراقی و مدل‌های رگرسیون منطقی	انتخاب یا ساخت روش پیش‌بینی باید متناسب با نوع، اندازه، و ریسک کسب‌وکار تعیین شود.

1. Virág & Nyitrai
2. Heo & Yang
3. Gordini

ادامه جدول ۲: خلاصه برخی پژوهش‌های حوزه ریسک اعتباری

پژوهشگران (سال)	هدف	روش‌های مورد استفاده	نتایج
سرنگ و همکاران ^۱ (۲۰۱۴)	ارائه چارچوبی برای ارزیابی احتمال قصور پیمانکار ساخت‌وساز بر پایه نسبت‌های مالی	رگرسیون لجستیک	افزودن فاکتور بازار به نقدینگی، اهرم، فعالیت و عوامل سودآوری می‌تواند دقت پیش‌بینی را افزایش دهد.
وانگ و همکاران (۲۰۱۴)	ارائه یک روش جدید و ارتقایافته FS-Boosting برای افزایش قدرت پیش‌بینی	FS-Boosting، الگوریتم‌های ژنتیک، رگرسیون لجستیک، ماشین بردار پشتیبان، رگرسیون لجستیک	دقت بالاتر FS-Boosting نسبت به سایر روش‌ها و به عنوان یک روش جایگزین برای پیش‌بینی ورشکستگی شرکت.
چو و همکاران (۲۰۱۷)	استفاده از روش ترکیبی هوش محاسباتی و نظریه آماری توسعه داده شده توسط الگوریتم ژنتیک و منطق فازی برای انتخاب نسبت‌های کلیدی	الگوریتم خوشه‌بندی فازی، الگوریتم ژنتیک	عملکرد بهتر مدل ترکیبی پیشنهادی نسبت به مدل غیر ترکیبی.
سون و همکاران (۲۰۱۹)	حل مسئله چولگی در توزیع نامتوازن برای پیش‌بینی ورشکستگی	شبکه عصبی مصنوعی و درخت Boosting	افزایش ۱۷ درصدی دقت پیش‌بینی با رفع مسئله چولگی.
سای و همکاران (۲۰۱۴)	به منظور مقایسه روش‌های طبقه‌بندی	روش‌های چندلایه پرسپترون، ماشین‌های بردار پشتیبان، درخت‌های تصمیم‌گیری	روش درخت‌های تصمیم‌گیری نسبت به سایر روش‌ها به طور قابل توجهی عملکرد بهتری در پیش‌بینی دارد.
هوانگ و همکاران ^۲ (۲۰۱۸)	مقایسه دقت الگوریتم‌های شبکه عصبی در ارزیابی ریسک اعتباری در مورد شرکت‌های کوچک و متوسط کشور چین	چندین مدل شبکه عصبی متداول در مجموعه داده‌های شرکت کوچک و متوسط	شبکه عصبی احتمالاتی (PNN) کم‌ترین میزان خطا به طور کلی و خطای نوع ۲ را دارد.

مقاله ۶- ارزیابی ریسک اعتباری با استفاده از مدل ترکیبی شبکه عصبی... | غلامرضا جندقی و همکاران

1. Tserng et al.
2. Huang et al.

همان‌طور که در جدول (۲) مشاهده می‌شود، بیش‌تر پژوهش‌های حوزه پیش‌بینی ورشکستگی با محوریت دو هدف اصلی انجام می‌شوند. این دو هدف محوری عبارت‌اند از ۱. ارائه مدلی برای بهبود دقت پیش‌بینی (Son et al., 2019; Liu et al., 2019; Chou et al., 2017; Jabeur, 2017; Du Jardin, 2015) و ۲. مقایسه روش‌های مختلف پیش‌بینی متناسب با یک جامعه آماری یا رویکرد خاص (Mai et al., 2019; Huang et al., 2018; Virág & Nyitrai, 2014; Gordini, 2014; Tsai et al., 2014). در شمار اندکی از پژوهش‌ها مانند زوریکاک و همکاران (۲۰۲۰)، دیبالی و زقدودی (۲۰۲۰)، و برتاینزکا و گریزیگورزوسکا (۲۰۱۸)، با اهدافی چون ارائه تحلیل‌های جامع انجام می‌شوند.

پژوهشگران مختلف بر اساس عوامل گوناگون اقدام به توسعه مدل خود می‌کنند که عوامل مهم‌تر آن‌ها عبارت‌اند از دقت، تفسیرپذیر بودن نتایج، اندازه نمونه، قابلیت لحاظ نمودن داده‌های پراکنده، انتخاب متغیرها، نوع متغیرها، رابطه متغیرها، مفروض‌ها، قابلیت انسجام، و به‌روز بودن (Alaka et al., 2018). در پژوهشی که هوانگ و همکاران (۲۰۱۸)، با هدف مقایسه دقت الگوریتم‌های شبکه عصبی در ارزیابی ریسک اعتباری در مورد شرکت‌های کوچک و متوسط کشور چین انجام می‌دهند، مدل آنان با دقت متوسط ۸۳ درصد قادر به پیش‌بینی ورشکستگی است. جابور (۲۰۱۷)، به منظور بالاتر بردن دقت مدل پیش‌بینی رگرسیون لجستیک از طریق لحاظ کردن طیف وسیع‌تر شاخص‌ها، مدل رگرسیون خطی حداقل مربع خطای بخشی را مورد استفاده قرار می‌دهد که مدل او قادر به برآورد ورشکستگی با دقت ۷/۹۳ درصد است. سِرنگ و همکاران (۲۰۱۴)، با استفاده از رگرسیون لجستیک با هدف پیش‌بینی نکول پیمانکاران، دقت مدل را ۷۹ درصد ارزیابی می‌کنند. وانگ و همکاران (۲۰۱۴)، داده‌های صورت‌های مالی ۱۳۲ شرکت را مورد تحلیل قرار می‌دهند و پیش‌بینی را با چهار روش شبکه عصبی، ماشین بردار پشتیبان، رگرسیون لجستیک، و درخت تصمیم انجام می‌دهند، و با این روش‌ها ورشکستگی را به‌ترتیب ۷۹/۶، ۷۳/۹، و ۷۶ درصد برآورد می‌کنند. ژو و همکاران (۲۰۱۴)، روش جدیدی برای انتخاب ویژگی معرفی می‌کنند و دقت برآوردی ایشان برای روش‌های شبکه عصبی، رگرسیون لجستیک، درخت تصمیم، تحلیل ممیزی چندگانه، و نزدیک‌ترین K همسایگی به‌ترتیب ۷۵/۶، ۷۳/۹، ۵۰/۶، و ۷۱/۷، و ۶۰/۹ درصد است. در جدول (۳)، خلاصه‌ای از این پژوهش‌ها و سایر پژوهش‌هایی که در آن پیش‌بینی با روش‌های مختلف تخمین‌زده شده باشد، نمایش داده می‌شود.

جدول ۳: خلاصه پژوهش‌های برآورد دقت پیش‌بینی احتمال ورشکستگی

پژوهشگران (سال)	حجم نمونه	شبکه عصبی	درصد برآوردشده			
			ماشین بردار پشتیبان	رگرسیون لجستیک	درخت تصمیم	تحلیل ممیزی چندگانه همسایگی
هوانگ و همکاران (۲۰۱۸)	۴۶	۸۳				
جایور (۲۰۱۷)			۹۳/۷۵			
ایتنوریانگا و سانز (۲۰۱۵)	۷۷۲	۹۳/۲۷	۸۹/۴۲			
دو جاردین (۲۰۱۵)	۱۶۸۱۰	۸۰/۸	۸۰/۶	۸۰/۱		
ویراگ و نیترا (۲۰۱۴)	۱۵۶	۸۸/۰۳	۸۹/۳۲		۸۹/۳۲ (RS)	
سای و همکاران (۲۰۱۴)	۵۹۰	۸۴/۳۸	۸۶/۳۷		۸۶/۳۷	
هو و یانگ (۲۰۱۴)	۲۷۶۲	۷۷/۱	۷۳/۳	۷۳/۱	۵۱/۳	
گردینی (۲۰۱۴)	۳۱۰۰	۶۹/۵	۶۶/۸		۷۱/۵ (GA)	
سرنگ و همکاران (۲۰۱۴)	۸۷		۷۹/۱۸			
وانگ و همکاران (۲۰۱۴)	۱۳۲	۷۵/۶۹	۷۹/۹۹	۷۳/۹	۷۵/۹۹	
ژو و همکاران (۲۰۱۴)	۲۰۱۰	۷۵/۶	۷۳/۹۹	۵۰/۶۷	۷۱/۷۲	۶۰/۹۹
آریشانتی و همکاران ^۱ (۲۰۱۳)	۲۴۰	۷۱	۷۰/۴۲		۷۵/۴۲	
سای و هسو ^۲ (۲۰۱۳)	۷۷/۲۹	۷۸/۸۲	۷۹/۱۱			
ژیونگ و همکاران ^۳ (۲۰۱۳)		۷۰/۹۴				
ژو و همکاران (۲۰۱۲)	۶۷/۸	۷۱/۱	۵۴/۴	۷۵/۶	۶۴/۴	۶۴/۴
دی‌آندرس و همکاران ^۴ (۲۰۱۲)	۱۲۲	۷۶/۰۳				۷۴/۸۷
دیچاردین و سورین ^۵ (۲۰۱۲)		۸۱/۳	۸۱/۶			۸۱/۲
جنونگ و همکاران ^۶ (۲۰۱۲)	۲۵۴۲	۸۱	۷۹	۷۶/۴۸	۷۶	۷۳/۵ (CBR)
شی و همکاران (۲۰۱۲)	۵۴	۷۵/۷۶	۸۱/۸۲	۷۲/۷۳	۷۷/۷۷	
دیوسالار و همکاران ^۱ (۲۰۱۱)	۱۳۶	۷۹/۴۱	۷۶/۴۷			

1. Arieshanti *et al.*
2. Tsai & Hsu
3. Xiong *et al.*
4. De Andrés *et al.*
5. Du Jardin & Séverin
6. Jeong *et al.*

داده جدول ۳: خلاصه پژوهش‌های برآورد دقت پیش‌بینی احتمال ورشکستگی

درصد برآورد شده							پژوهشگران (سال)	
سایر روش‌ها	نزدیک‌ترین همسایگی K	تحلیل مسیری چندگانه	درخت تصمیم	رگرسیون لجستیک	ماشین بردار پشتیبان	شبکه عصبی		
	۷۸/۷۵				۷۶/۶۷	۷۹/۵۸	۲۴۰	چن و همکاران (۲۰۱۱)
					۷۹	۷۸/۳۳	۱۲۰	یانگ و همکاران ^۲ (۲۰۱۱)
		۷۰/۱		۷۰/۱	۷۴/۲	۷۳/۱	۱۰۰۰۰	یون و ون ^۳ (۲۰۱۰)
						۷۱/۰۲	۱۴۵۸	کیم و کانگ ^۴ (۲۰۱۰)
			۶۵/۷	۷۲/۲		۷۱/۸	۱۰۰۰	چو و همکاران ^۵ (۲۰۱۰)
						۸۷/۵	۸۴	ناظمی اردکانی (۱۳۹۴)

روش‌شناسی پژوهش

با مطالعات کتابخانه‌ای و مرور ادبیات، متغیرهای اثرگذار در حوزه ریسک اعتباری شناسایی می‌شوند. داده‌های مالی شامل ترازنامه، صورت سود و زیان، گردش وجوه نقد، و نسبت‌های مالی برای دوره ۲۶ ساله شامل شرکت‌هایی است که از سال ۱۳۷۰ تا سال ۱۳۹۵ در بورس اوراق بهادار تهران یا فرابورس حضور داشته‌اند. داده‌ها از نرم‌افزار سازمان بورس (ره‌آورد نوین) جمع‌آوری می‌شود. بررسی شرکت‌های حاضر در بورس و فرابورس به این دلیل است که شرکت‌ها با احتمال بیش‌تری دارای شفافیت مالی و صحت اطلاعات ارائه‌شده هستند (Zoričák et al., 2020). داده‌های اولیه مربوط به ۷۵۹ شرکت است. در مرحله بعد، غربال اولیه صورت می‌گیرد و از آن‌جا که ریسک اعتباری برای بررسی وضعیت اعتباری شرکت‌ها به عنوان نهاد تسهیلات‌گیرنده از بانک‌ها و موسسه‌های مالی بررسی می‌شود، و ریسک اعتباری خود نهادها موضوع بررسی پژوهش حاضر نیست، شرکت‌ها و موسسه‌های پولی و مالی و بانک‌ها از شرکت‌های مورد بررسی حذف می‌شوند. از آن‌جا که در مجموعه داده‌های انتخابی تعداد نمونه‌های ورشکسته کم‌تر از سالم است، و این بی‌توازنی دقت

1. Divsalar et al.
2. Yang et al.
3. Yoon & Kwon
4. Kim & Kang
5. Cho et al.

مدل را کاهش می‌دهد (Volkov et al., 2017; kim et al., 2016)، از داده‌های ثانویه برای بررسی وضعیت شرکت‌های سالم و ورشکسته استفاده می‌شود که این داده‌های ثانویه شامل کل نمونه ورشکسته و تعداد تقریباً همسانی از نمونه‌های سالم است که به صورت تصادفی از مجموعه کل نمونه‌های سالم انتخاب می‌شوند. برای نمونه ورشکسته، شرکت‌هایی با سه سال فعالیت متوالی غیرمشمول در تعریف ورشکستگی و سال چهارم مشمول ورشکستگی تعریف می‌شود، که ۱۰۸ شرکت با این شرایط یافت به دست آمد. نمونه سالم نیز شامل شرکت‌هایی با چهار سال فعالیت متوالی و مشمول نشدن در تعریف ورشکستگی است، که با نمونه‌گیری تصادفی ۱۱۰ نمونه انتخاب می‌شود. داده‌ها و متغیرها به عنوان ورودی الگوریتم کلاسیک مورچگان از طریق نرم‌افزار مورد تحلیل می‌گیرند و موثرترین ویژگی‌ها تعیین می‌شوند. سپس از متغیرهای استخراج شده در طبقه‌بندی با الگوریتم بازشناسی الگوی شبکه‌های عصبی استفاده می‌شود. همچنین، طبقه‌بندی در نرم‌افزار متلب^۱ نسخه ۱۴ صورت می‌گیرد که در ادامه پژوهش گزارش می‌شود.

مبنای تشخیص ورشکستگی، ماده (۱۴۱) اصلاحیه قانون تجارت معیار شرکت‌هاست. بر اساس قانون تجارت با تدوین منصور (۱۳۹۹)، اگر بر اثر زیان‌های وارد شده دست‌کم نصف سرمایه شرکت از بین برود، هیئت‌مدیره مکلف است بلافاصله مجمع عمومی فوق‌العاده صاحبان سهام را دعوت کند تا موضوع انحلال یا بقای شرکت مورد شور و رأی قرار گیرد. با توجه به این که ۷۵۹ شرکت در دوره ۲۶ ساله مورد بررسی قرار می‌گیرد، مواردی که شرکت‌ها در دو سال متوالی سالم باشند یا در یک سال سالم و در سال بعد ورشکسته شده باشند، زیاد است. در این پژوهش سال مبنا را t و سال‌های ماقبل آن را به ترتیب $t-1$ ، $t-2$ ، و $t-3$ نامیده می‌شود. این چهار سال در مورد هر شرکت، از بازه ۲۶ ساله مورد بررسی پژوهش و متناسب با ویژگی نمونه ورشکسته و سالم انتخاب می‌شوند، به این ترتیب سال مبنای نمونه‌های مختلف با هم متفاوت است. همان‌طور که پیش‌تر اشاره شد، در این پژوهش و در جهت بالا بردن دقت اندازه، شرکت‌هایی که سه سال متوالی سالم هستند و سپس در سال چهارم ورشکسته می‌شوند، به عنوان شرکت‌های ورشکسته و شرکت‌هایی که در چهار سال متوالی سالم باشند، به عنوان سالم دسته‌بندی می‌شوند. بنابراین، نیاز به حجم قابل توجه داده برای استخراج شرکت‌هایی با این شرایط خاص احساس می‌شود.

داده‌ها و آمار توصیفی

برای استخراج بااهمیت‌ترین عوامل موثر بر ریسک اعتباری، شاخص‌ها از ادبیات استخراج می‌شوند که در مجموع ۲۴ عامل شامل سود انباشته به کل دارایی، فروش به کل دارایی، EBIT به کل دارایی، EBIT به فروش کل، سود ناخالص به فروش کل، کل بدهی به کل دارایی، کل حقوق صاحبان سهام به کل بدهی، بدهی‌های جاری به کل بدهی‌ها، سرمایه در گردش به کل دارایی‌ها، نسبت جاری، نسبت آنی، نسبت وجه نقد، حاشیه سود خالص، بازده حقوق صاحبان سهام، نسبت حقوق صاحبان سهام به دارایی کل، نسبت دوپونت، بازده دارایی‌ها (ROA)، بازده سرمایه در گردش، بازده دارایی ثابت، نسبت دارایی‌های جاری، دوره موجودی کالا و مواد، دوره وصول مطالبات، نسبت کالا به سرمایه در گردش، و گردش دارایی‌های ثابت شناسایی می‌شوند. در جدول (۴)، اختلاف میانگین داده‌های شرکت‌های سالم و ورشکسته در مورد متغیرها (نسبت‌ها)ی اشاره‌شده آورده می‌شود.

جدول ۴: اختلاف میانگین داده‌های شرکت‌های سالم و ورشکسته

ردیف	متغیرها (نسبت‌ها)	نام اختصاری	میانگین شرکت‌های سالم	میانگین شرکت‌های ورشکسته	میانگین کل	قدرمطلق نسبت میانگین‌ها
۱	سود انباشته به کل دارایی	RE/TA	۰/۱۳۸	-۰/۰۷۱	۰/۰۳۴	%۱۹۳
۲	فروش به کل دارایی	S/TA	۰/۱۱۷	۰/۰۱۱	۰/۰۶۵	%۱۰۱۸
۳	EBIT به کل دارایی	EBIT/TA	۰/۸۲۳	۰/۷۱۵	۰/۷۷۰	%۱۱۵
۴	EBIT به فروش کل	EBIT/TS	۰/۱۵۶	-۰/۰۲۲	۰/۰۶۷	%۷۰۲
۵	سود ناخالص به فروش کل	GP/TS	۰/۲۳۷	۰/۱۱۴	۰/۱۷۶	%۲۰۷
۶	کل بدهی به کل دارایی	TD/TA	۰/۵۹۱	۰/۸۰۶	۰/۶۹۷	%۷۳
۷	کل حقوق صاحبان سهام به کل بدهی	TE/TD	۰/۹۵۵	۰/۲۹۶	۰/۶۲۸	%۳۲۳
۸	بدهی‌های جاری به کل بدهی‌ها	CUL/TL	۰/۸۷۴	۰/۸۴۴	۰/۸۵۹	%۱۰۴
۹	سرمایه در گردش به کل دارایی‌ها	WC/TA	۰/۱۲۷	۰/۰۲۲	۰/۰۷۵	%۵۸۲
۱۰	نسبت جاری	CUR	۱/۴۷۲	۱/۰۸۴	۱/۲۸۰	%۱۳۶
۱۱	نسبت آنی	QUR	۰/۹۳۷	۰/۵۵۱	۰/۷۴۶	%۱۷۰
۱۲	نسبت وجه نقد	CAR	۰/۱۷۰	۰/۰۶۲	۰/۱۱۶	%۲۷۳
۱۳	حاشیه سود خالص	NIM	۰/۱۲۵	-۰/۱۳۶	-۰/۰۰۴	%۹۲
۱۴	بازده حقوق صاحبان سهام	ROE	۰/۲۳۰	-۰/۰۹۴	۰/۰۶۹	%۲۴۵

ادامه جدول ۴: اختلاف میانگین داده‌های شرکت‌های سالم و ورشکسته

ردیف	متغیرها (نسبت‌ها)	نام اختصاری	میانگین شرکت‌های سالم	میانگین شرکت‌های ورشکسته	میانگین کل	قدر مطلق نسبت میانگین‌ها
۱۵	نسبت حقوق صاحبان سهام به دارایی کل	TA/TSE	۳/۲۶۷	۶/۵۲۹	۴/۸۸۳	۵۰٪
۱۶	نسبت دوپونت	DuP	۷۷/۹۴۷	-۱۶/۵۰۵	۳۱/۱۵۴	۴۷۲٪
۱۷	بازده دارایی‌ها (ROA)	ROA	۰/۰۸۷	-۰/۰۱۸	۰/۰۳۵	۴۸۸٪
۱۸	بازده سرمایه در گردش	RWC	۰/۲۲۰	-۱/۱۶۰	-۰/۴۶۴	۱۹٪
۱۹	بازده دارایی ثابت	RFA	۰/۸۱۲	-۱/۲۸۵	-۰/۲۲۷	۶۳٪
۲۰	نسبت دارایی‌های جاری	CUA	۰/۶۳۹	۰/۷۰۵	۰/۶۷۲	۹۱٪
۲۱	دوره موجودی کالا و مواد	MIP	۱۹۹/۴	۴۲۲	۳۰۹/۶	۴۷٪
۲۲	دوره وصول مطالبات	RCP	۲۳۴	۲۰۸	۲۲۱	۱۱۲٪
۲۳	نسبت کالا به سرمایه در گردش	IN/WC	۱/۶۸۲	-۰/۲۳۷	۰/۷۳۱	۷۰۹٪
۲۴	گردش دارایی‌های ثابت	FAT	۰/۰۶۴	۰/۰۷۶	۰/۰۷۰	۸۴٪

هرچند که با توجه به جدول (۴) به نظر می‌رسد با توجه به اختلاف میانگین شرکت‌های سالم و ورشکسته، امکان شناسایی عوامل موثرتر وجود دارد، ولی نتایج پژوهش نشان می‌دهد که اختلاف میانگین نسبت‌های اشاره‌شده نمی‌تواند به عنوان یک عامل ممیزکننده مناسب در شناسایی عوامل موثرتر مفید واقع شود. با این حال و به دلیل ایجاد تصویری کلی از سازوکار اثر نسبت‌ها، ضریب اختلاف میانگین آن‌ها ارائه می‌شود. در جدول (۵)، ویژگی‌های جمعیت‌شناختی ۲۱۸ شرکت انتخابی آورده می‌شود.

جدول ۵: ویژگی‌های جمعیت‌شناختی شرکت‌های نمونه

ردیف	صنعت	تعداد شرکت‌های انتخابی در صنعت	مجموع حجم درآمد شرکت‌های انتخابی در سال ۱۳۹۵ (به میلیون ریال)	درصد درآمد شرکت‌های انتخابی نسبت به کل شرکت‌های آن صنعت در بازار سرمایه در سال ۱۳۹۵
۱	انبوه‌سازی املاک و مستغلات	۴	۱/۲۸۰/۷۶۵	۷٪
۲	استخراج کانه‌های فلزی	۴	۲/۵۳۵/۰۹۳	۵٪
۳	کاشی و سرامیک	۴	۵۱۶/۱۱۸	۱۲٪
۴	قند و شکر	۹	۱۱/۰۵۸/۸۸۸	۵۷٪

ادامه جدول ۵: ویژگی‌های جمعیت شناختی شرکت‌های نمونه

ردیف	صنعت	تعداد شرکت‌های انتخابی در صنعت	مجموع حجم درآمد شرکت‌های انتخابی در سال ۱۳۹۵ (به میلیون ریال)	درصد درآمد شرکت‌های انتخابی نسبت به کل شرکت‌های آن صنعت در بازار سرمایه در سال ۱۳۹۵
۵	سیمان آهک گچ	۱۲	۱۱/۲۲۶/۴۳۹	٪۴۱
۶	دستگاه‌های برقی	۹	۱۴/۶۵۳/۹۸۰	٪۸۸
۷	لاستیک و پلاستیک	۴	۵/۱۴۰/۱۰۱	٪۲۷
۸	غذایی به‌جز قند و شکر	۱۷	۹/۳۷۲/۲۱۷	٪۱۸
۹	محصولات فلزی	۱۰	۵/۱۵۷/۲۶۳	٪۸۳
۱۰	ماشین‌آلات و تجهیزات	۲۰	۱۰/۶۳۰/۱۶۰	٪۵۵
۱۱	کانی غیرفلزی	۱۴	۵/۲۳۵/۳۷۹	٪۶۰
۱۲	دارویی	۱۹	۳۰/۷۶۷/۰۴۵	٪۴۵
۱۳	شیمیایی	۱۷	۱۲۲/۴۷۴/۹۰۸	٪۳۴
۱۴	منسوجات	۱۷	۶۳۳/۱۳۹	٪۳۶
۱۵	فلزات اساسی	۱۷	۱۲۵/۰۰۰/۰۰۰	٪۳۶
۱۶	خودرو و قطعات	۱۴	۱۵۹/۰۰۰/۰۰۰	٪۳۴
۱۷	سایر صنایع*	۲۷	۱۱۰/۹۹۰/۵۰۲	-

* سایر صنایع شامل صنایع ۱. فرآورده‌های نفتی؛ ۲. عرضه برق، گاز، بخار و آب گرم؛ ۳. پیمانکاری صنعتی؛ ۴. فنی و مهندسی؛ ۵. محصولات کاغذی؛ ۶. استخراج سایر معادن؛ ۷. محصولات چوبی؛ ۸. تجارت عمده و خرده‌فروشی وسایل نقلیه موتوری؛ ۹. استخراج زغال‌سنگ؛ ۱۰. محصولات چرمی؛ ۱۱. وسایل ارتباطی؛ ۱۲. رایانه؛ ۱۳. حمل‌ونقل انبارداری و ارتباطات؛ ۱۴. چاپ؛ و ۱۵. زراعت و خدمات وابسته می‌شود.

نتایج تجربی

برای انتخاب بهترین ویژگی‌ها، ۲۴ متغیر به همراه داده‌های آن‌ها از ۲۱۸ شرکت شامل ۱۱۰ شرکت سالم (با چهار سال فعالیت متوالی و مشمول ورشکسته نشدن)، و ۱۰۸ شرکت ورشکسته (با سه سال فعالیت متوالی و مشمول ورشکسته نشدن و ورشکستگی در سال چهارم) وارد نرم‌افزار متلب می‌شوند و الگوریتم کلونی مورچگان به انتخاب بهترین ویژگی‌ها از میان ۲۴ متغیر می‌پردازد. پنج متغیر شامل EBIT به فروش کل، کل حقوق صاحبان سهام به کل بدهی، نسبت جاری، نسبت وجه نقد، و نسبت حقوق صاحبان سهام به دارایی کل به عنوان بهترین ویژگی‌ها انتخاب می‌شود. در جدول (۶)، میانگین شرکت‌های سالم، ورشکسته، و کل هر یک از شاخص‌های انتخابی برای سال‌های t-1، t-2، t، و t-3 آورده می‌شود.

جدول ۶: میانگین شرکت‌های سالم، ورشکسته، و کل هر یک از شاخص‌های انتخابی

عوامل	میانگین شرکت‌های سالم				میانگین شرکت‌های ورشکسته				میانگین کل			
	t	t-1	t-2	t-3	t	t-1	t-2	t-3	t	t-1	t-2	t-3
EBIT/TS	۹/۹۷۵	۵/۳۸۵	-۲/۲۱۵	-۸۰۶۷	۲۴/۸۴۵	۱۹/۲۷۶	۱۵/۵۵۲	۱۶/۰۷	۱۷/۴۷۸	۱۲/۳۹۵	۶/۷۵۰	-۳۹۸۸
TE/TD	۰/۶۰۲	۰/۴۸۴	۰/۲۹۶	۰/۰۷۵	۱/۰۱۰	۰/۳۳۵	۰/۹۵۵	۰/۹۵۳	۰/۸۰۸	۰/۷۱۱	۰/۶۲۸	۰/۵۱۸
CUR	۱/۳۷۷	۱/۲۷۶	۱/۰۸۴	۰/۸۳۸	۱/۵۸۵	۱/۵۲۶	۱/۴۷۲	۱/۴۸۲	۱/۴۸۲	۱/۴۰۲	۱/۲۸۰	۱/۱۶۳
CAR	۰/۱۱۸	۰/۰۹۰	۰/۰۶۲	۰/۰۴۴	۰/۲۳۶	۰/۱۷۲	۰/۱۷۰	۰/۱۵۴	۰/۱۷۸	۰/۱۳۱	۰/۱۱۶	۰/۰۹۹
TA/TSE	۵/۴۱۸	۴/۶۷۶	۶/۵۲۹	-۷۹/۶۲	۳/۰۸۸	۳/۱۳۲	۳/۲۶۷	۳/۳۲۴	۴/۲۴۳	۳/۸۹۷	۴/۸۸۳	-۳۷/۷۶

این پنج متغیر با طبقه‌بندی الگوریتم بازشناسی الگو مورد تحلیل قرار می‌گیرند. از میان ۱۱۰ شرکت سالم، ۸۹ شرکت به عنوان مجموعه آموزش، و ۲۱ شرکت به عنوان مجموعه نمونه انتخاب می‌شوند. از میان ۸۹ شرکت سالم مجموعه آموزش، مدل قادر به تشخیص صحیح ۶۶ شرکت است و ۲۳ شرکت باقی‌مانده سالم در دسته شرکت‌های ورشکسته دسته‌بندی می‌شوند. در واقع، در مورد این ۲۳ شرکت خطای نوع ۱ رخ داده است. دقت پیش‌بینی شرکت‌های سالم برای مجموعه آموزش نیز ۷۴/۱۵ درصد است. در مورد ۲۱ شرکت سالم مجموعه نمونه، مدل قادر به تشخیص صحیح ۱۵ عدد از آن‌هاست و ۶ شرکت سالم نیز در دسته شرکت‌های ورشکسته جای می‌گیرند. بنابراین، دقت پیش‌بینی شرکت‌های سالم برای مجموعه نمونه نیز ۷۱/۴۲ درصد است. دقت مدل در برآورد شرکت‌های سالم (مجموعه آموزش و مجموعه نمونه) ۷۳/۶۳ درصد است.

از میان ۱۰۸ شرکت ورشکسته ۸۵ شرکت به عنوان مجموعه آموزش و ۲۳ شرکت به عنوان مجموعه نمونه انتخاب می‌شوند. از میان ۸۵ شرکت ورشکسته مجموعه آموزش، مدل قادر به تشخیص صحیح ۸۱ شرکت است و ۴ شرکت باقی‌مانده ورشکسته در دسته شرکت‌های سالم دسته‌بندی می‌شوند. در واقع، در مورد این ۴ شرکت خطای نوع ۲ رخ داده است. دقت پیش‌بینی شرکت‌های ورشکسته برای مجموعه آموزش نیز ۹۵/۲۹ درصد است. در مورد ۲۳ شرکت ورشکسته مجموعه نمونه، مدل قادر به تشخیص صحیح ۲۰ عدد از آن‌هاست و ۳ شرکت ورشکسته نیز در دسته شرکت‌های سالم جای می‌گیرند. بنابراین، دقت پیش‌بینی شرکت‌های ورشکسته برای مجموعه نمونه نیز ۸۶/۹۵ درصد است. دقت مدل در برآورد شرکت‌های ورشکسته (مجموعه آموزش و مجموعه نمونه) ۹۳/۵۱ درصد است.

از میان ۲۱۸ شرکت سالم و ورشکسته، ۱۷۴ شرکت به عنوان مجموعه آموزش و ۴۴ شرکت به عنوان مجموعه نمونه انتخاب می‌شوند. از بین ۱۷۴ شرکت مجموعه آموزش، مدل قادر به تشخیص صحیح ۱۴۷ شرکت است و دقت پیش‌بینی مدل برای شرکت‌های مجموعه آموزش ۸۴/۴۸ درصد

است. از میان ۴۴ شرکت سالم و ورشکسته مجموعه نمونه، مدل قادر به تشخیص صحیح ۳۵ شرکت است و دقت پیش‌بینی مدل برای شرکت‌های مجموعه نمونه ۷۹/۵۴ درصد است. در نهایت، از میان ۲۱۸ شرکت سالم و ورشکسته، مدل قادر به تشخیص صحیح ۱۸۲ شرکت است و دقت برآورد کل ۴۸/۸۳ درصد است. تحلیل برای سال‌های t-2 و t-3 نیز انجام می‌شود و نتایج آن برای شرکت‌های سالم در جدول (۷)، شرکت‌های ورشکسته در جدول (۸)، و کل در جدول (۹) نشان داده می‌شود.

جدول ۷: دقت پیش‌بینی ریسک اعتباری شرکت‌های سالم سال t با استفاده از داده‌های سال‌های قبل

نوع داده	بر اساس داده‌های سال t و t-1		بر اساس داده‌های سال t و t-2		بر اساس داده‌های سال t و t-3	
	تعداد	درصد	تعداد	درصد	تعداد	درصد
مجموعه آموزش	۸۹	۸۹	۸۹	۸۹	۹۱	۹۱
	۶۶	٪۷۴/۱۶	۴۹	٪۵۵/۰۶	۵۵	٪۶۰/۴۴
برآورد صحیح	۶۶	٪۷۴/۱۶	۴۹	٪۵۵/۰۶	۵۵	٪۶۰/۴۴
	۲۳	٪۲۵/۸۴	۴۰	٪۴۴/۹۴	۳۶	٪۳۹/۵۶
مجموعه نمونه	۲۱	۲۱	۲۱	۲۱	۱۹	۱۹
	۱۵	٪۷۱/۴۳	۱۲	٪۵۷/۱۴	۷	٪۳۶/۸۴
برآورد صحیح	۱۵	٪۷۱/۴۳	۱۲	٪۵۷/۱۴	۷	٪۳۶/۸۴
	۶	٪۲۸/۵۷	۹	٪۴۲/۸۶	۱۲	٪۶۳/۱۶

جدول ۸: دقت پیش‌بینی ریسک اعتباری شرکت‌های ورشکسته سال t با استفاده از داده‌های سال‌های قبل

نوع داده	بر اساس داده‌های سال t و t-1		بر اساس داده‌های سال t و t-2		بر اساس داده‌های سال t و t-3	
	تعداد	درصد	تعداد	درصد	تعداد	درصد
مجموعه آموزش	۸۵	۸۵	۸۵	۸۵	۸۳	۸۳
	۸۱	٪۹۵/۲۹	۷۹	٪۹۲/۹۴	۷۵	٪۹۰/۳۹
برآورد صحیح	۸۱	٪۹۵/۲۹	۷۹	٪۹۲/۹۴	۷۵	٪۹۰/۳۹
	۴	٪۴/۷۱	۶	٪۷/۰۶	۸	٪۹/۶۴
مجموعه نمونه	۲۳	۲۳	۲۳	۲۳	۲۵	۲۵
	۲۰	٪۸۶/۹۶	۲۱	٪۹۱/۳	۲۱	٪۸۴
برآورد صحیح	۲۰	٪۸۶/۹۶	۲۱	٪۹۱/۳	۲۱	٪۸۴
	۳	٪۱۳/۰۴	۲	٪۸/۷	۴	٪۱۶

جدول ۹: دقت پیش‌بینی ریسک اعتباری کل، سال t با استفاده از داده‌های سال‌های قبل

نوع داده	بر اساس داده‌های سال t-1		بر اساس داده‌های سال t و t-2		بر اساس داده‌های سال t و t-3	
	تعداد	درصد	تعداد	درصد	تعداد	درصد
مجموعه آموزش	۱۷۴		۱۷۴		۱۷۴	
	۱۴۷	٪۸۴/۴۸	۱۲۸	٪۷۳/۵۶	۱۳۰	٪۷۴/۷۱
برآورد اشتباه	۲۷	٪۱۵/۵۲	۴۶	٪۲۶/۴۴	۴۴	٪۲۵/۲۹
	۴۴		۴۴		۴۴	
مجموعه نمونه	۳۵	٪۷۹/۵۵	۳۳	٪۷۵	۲۸	٪۶۳/۳۶
	۹	٪۲۰/۴۵	۱۱	٪۲۵	۱۶	٪۳۶/۳۶
کل	۲۱۸		۲۱۸		۲۱۸	
	۱۸۲	٪۸۳/۴۹	۱۶۱	٪۷۳/۸۵	۱۵۸	٪۷۲/۴۸
برآورد اشتباه	۳۶	٪۱۶/۵۱	۵۷	٪۲۶/۱۵	۶۰	٪۲۷/۵۲

جدول (۱۰)، بررسی تطبیقی نتایج پژوهش را از نظر دقت پیش‌بینی با سایر پژوهش‌ها نشان می‌دهد. مطابق خروجی به‌دست‌آمده، پیش‌بینی برای مجموعه آموزش با دقت ۸۴/۴۸ درصد، برای مجموعه نمونه با دقت ۷۹/۵۵ درصد، و در مجموع با دقت ۸۳/۴۹ است. دقت پیش‌بینی با استفاده از داده‌های دو سال قبل نسبت به دقت پیش‌بینی با استفاده از داده‌های سال قبل کاهش دارد و پیش‌بینی با دقت ۷۳/۵۶ درصد برای مجموعه آموزش، ۷۵ درصد برای مجموعه نمونه، و در مجموع با دقت ۷۳/۸۵ درصد است. با داده‌های سه سال قبل نیز نتیجه، دقت ۷۴/۷۱ درصد برای مجموعه آموزش، ۶۳/۳۶ درصد برای مجموعه نمونه، و در مجموع ۷۲/۴۸ دقت کل است. دقت خروجی حاصل از پیش‌بینی وضعیت اعتباری شرکت با استفاده از داده‌های هر سه سال نشان می‌دهد که متغیرهای انتخاب‌شده با دقت بالایی قادر به پیش‌بینی وضعیت اعتباری شرکت در سال یا سال‌های بعد هستند. در جدول (۱۰)، میانگین دقت به‌دست‌آمده از روش‌هایی که بیش‌ترین فراوانی را در برآورد احتمال نکول دارند، گزارش می‌شود.

جدول ۱۰: بررسی تطبیقی نتایج پژوهش حاضر با پژوهش‌های پیشین

عنوان	میانگین درصدها				
پژوهش شبکه ماشین بردار رگرسیون درخت تحلیل ممیزی نزدیک‌ترین حاضر عصبی پشتیبان لجستیک تصمیم چندگانه k همسایگی	۲۱	۱۶	۱۴	۸	۴
تعداد	۸۳/۴۹	۷۷/۹۹	۷۵/۰۹	۷۲/۶۵	۷۰/۹
درصد	۶۹/۸۹	۷۸/۱۹	۶۹/۸۹	۶۹/۸۹	۶۹/۸۹

برخی از روش‌ها قادر هستند با درصد دقت به نسبت بالایی وضعیت اعتباری شرکت را پیش‌بینی کنند. همچنین، این پژوهش‌ها در جوامع آماری و در سال‌های مختلف انجام می‌شوند و منطقی است که هرچه عوامل محیط کلان شرکت و وضعیت مالی و اقتصادی جامعه بیش‌تر دچار نوسان‌های بزرگ شوند، احتمال برآورد صحیح نیز کاهش یابد. همان‌طور که در جدول (۱۰) روشن است، مدل‌های مختلف به‌طور میانگین با دقت بین ۶۹/۸۹ درصد برای روش نزدیک‌ترین k همسایگی تا ۷۸/۱۹ برای روش ماشین بردار قادر به پیش‌بینی وضعیت اعتباری شرکت هستند.

بحث و نتیجه‌گیری

هدف از انجام پژوهش حاضر شناسایی مهم‌ترین متغیرهای موثر در ریسک اعتباری و طبقه‌بندی آن است. برای انتخاب ویژگی از الگوریتم کلونی مورچگان و برای طبقه‌بندی از الگوریتم بازشناسی الگو استفاده شده است. بر اساس نتایج پژوهش و انتخاب ویژگی انجام‌شده به وسیله الگوریتم کلونی مورچگان، پنج متغیر شامل سود قبل از کسر بهره و مالیات به فروش کل، کل حقوق صاحبان سهام به کل بدهی، نسبت جاری، نسبت وجه نقد، و نسبت حقوق صاحبان سهام به دارایی کل به عنوان بهترین ویژگی‌ها انتخاب می‌شوند. با توجه به انتخاب پنج نسبت به عنوان موثرترین عوامل در پیش‌بینی ورشکستگی و وضعیت اعتباری شرکت‌ها، اقلام موجود در ترازنامه و صورت سود و زیان شرکت شامل سود قبل از بهره و مالیات، کل حقوق صاحبان سهام، دارایی جاری (از صورت کسر نسبت جاری)، وجوه نقد، و سایر دارایی‌ها با امکان نقدشوندگی سریع (از صورت کسر نسبت وجه نقد) از اهمیت ویژه‌ای برخوردار است و با توجه به این‌که اقلام به صورت نسبت در معادله وضعیت اعتباری قرار می‌گیرند، میزان قابل قبول هر یک از آن‌ها با توجه به اقلامی که در مخرج کسر می‌آید، تعیین می‌شود. با استفاده از داده‌های ویژگی‌های اشاره‌شده، طبقه‌بندی شرکت‌های نمونه انجام می‌شود. مطابق نتایج، امکان پیش‌بینی احتمال ورشکستگی

شرکت‌ها با دقت بالایی برای مجموعه آموزش، مجموعه نمونه، و کل وجود دارد. معنای استفاده از داده‌های یک‌سال قبل در پیش‌بینی این است که افق بررسی یک‌ساله است. دقت خروجی مدل در این حالت بیان می‌دارد که اگر با داده‌هایی که هم‌اکنون در اختیار داریم، بخواهیم وضعیت یک شرکت را در سال آینده بررسی کنیم، دقت پیش‌بینی مدل چقدر است. این خروجی بسیار پراهمیت است زیرا با توجه به این که در مدل‌های پیش‌بینی مبتنی بر زمان، پیش‌بینی زمان نزدیک‌تر با استفاده از اطلاعات جاری دقیق‌تر از پیش‌بینی نسبت به زمان دورتر است، در حالتی که با استفاده از داده‌های سال جاری بخواهیم وضعیت اعتباری یک شرکت را در سال آینده پیش‌بینی کنیم، دقت مدل نسبت به حالتی که می‌خواهیم با همین اطلاعات، وضعیت اعتباری دو یا سه سال آینده را اندازه‌گیری کنیم، بیش‌تر است. در ضمن، بسیاری از تعهدهای مربوط به تسهیلات در دوره کوتاه‌مدت ایجاد می‌شود و این که بتوانیم وضعیت اعتباری یک شرکت را در دوره کوتاه‌مدت با دقت بالا برآورد کنیم، بسیار مهم است. در پژوهش حاضر، دقت برآورد در افق یک‌ساله ۸۳/۴۹ درصد است. با این حال، به‌ویژه در مواردی که از سوی بانک‌ها و مراکز مالی و اعتباری تسهیلات بلندمدت به شرکت‌ها اعطا می‌شود، هم وضعیت اعتباری کوتاه‌مدت و هم بلندمدت شرکت‌ها اهمیت پیدا می‌کند. دقت برآوردی در افق دوساله ۷۳/۸۵ درصد و در افق سه‌ساله ۷۲/۴۸ درصد است.

در این پژوهش، هر دو عملیات انتخاب ویژگی و طبقه‌بندی با استفاده از روش‌های یادگیری ماشینی از قبیل الگوریتم مورچگان و الگوریتم بازشناسی الگوی شبکه‌های عصبی صورت گرفته است، در حالی که در بیش‌تر پژوهش‌های مشابه، انتخاب ویژگی یا با مطالعه ادبیات و نظر پژوهشگران یا با استفاده از روش‌هایی با دقت پایین‌تر انجام شده است. لازمه استفاده از روش‌های یادگیری ماشینی، مانند دو روش اشاره‌شده، وجود حجم مناسبی از داده است که این داده‌ها برای آموزش الگوریتم و برآورد مورد استفاده قرار بگیرند. به همین دلیل در پژوهش حاضر بررسی در یک بازه زمانی ۲۶ ساله انجام می‌گیرد که به بالاتر رفتن حجم داده‌های مورد بررسی منجر می‌شود. با توجه به نتایج به‌دست‌آمده و امکان بررسی وضعیت اعتباری شرکت‌ها با دقت قابل‌قبول، پیشنهاد پژوهش حاضر برای تصمیم‌گیرندگان حوزه بانکی و موسسه‌های مالی، حرکت از ارزیابی سنتی وضعیت اعتباری به ارزیابی بر اساس مدل‌های نوین و مبتنی بر یادگیری ماشینی است تا بدین وسیله ریسک ناشی از عمل نکردن به تعهد شرکت‌ها کاهش یابد و کم‌تر دچار هزینه‌های سنگین حاصل از آن شوند. به سرپرستان و مدیران حوزه ریسک اعتباری در این موسسه‌ها نیز توصیه می‌شود که مدل ارزیابی ریسک اعتباری‌شان را با تاکید بر دو فاز مهم انتخاب ویژگی و

طبقه‌بندی بر اساس روش‌های دقیق طراحی کنند و از بروز خطای مبتنی بر قضاوت در تعیین شاخص‌های ریسک اعتباری خودداری کنند.

بررسی روی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران و فرابورس انجام شده است که وضعیت صورت‌های مالی آنان نسبت به شرکت‌های نوپا و کوچک و متوسطی که سرمایه اصلی‌شان دانش فنی است، و می‌توانند ظرفیت رشد بالایی داشته باشند، بهتر است. به همین دلیل، خروجی این پژوهش و سایر پژوهش‌های حوزه ریسک اعتباری و ورشکستگی برای ارزیابی این دسته از شرکت‌ها می‌تواند گمراه‌کننده باشد. برای پژوهش‌های آتی پیشنهاد می‌شود که موضوع وضعیت اعتباری و پیش‌بینی ورشکستگی، برای شرکت‌هایی با ویژگی‌های اشاره‌شده مورد بررسی قرار گیرد. در حوزه ادبیات نظری تاکید زیادی بر بهینه‌سازی روش‌ها و بالا بردن دقت پیش‌بینی مدل‌ها و اثبات اثرگذاری آن‌ها می‌شود، در حالی که کم‌تر به عوامل اثرگذاری پرداخته می‌شود که جدا از پیش‌فرض‌های جاری بتوانند دقت خروجی را بالا ببرند و همچنین تحت شرایط خاص مثل شرایط بحرانی نیز کارایی خود را زیاد از دست ندهند و بتوانند خروجی قابل‌قبولی ارائه دهند. از آن‌جا که، به‌ویژه در مرحله انتخاب ویژگی، داده‌های مربوط به شرکت‌های نمونه از نظر شاخص‌های گوناگون بررسی شده است، فقدان برخی داده‌ها مربوط به برخی اقلام صورت‌های مالی شرکت‌ها در برخی سال‌ها از جمله محدودیت‌های مهم پژوهش حاضر است. این محدودیت با افزایش سال‌های مورد بررسی و به دنبال آن تعداد نمونه قابل‌بررسی تا حد زیادی برطرف شده است. محدودیت دیگر کمبود پژوهش‌هایی است که در حوزه ریسک اعتباری به انتخاب ویژگی پرداخته باشند.

منابع

الف) فارسی

- خلیلی، جواد، و علی‌نژاد، علیرضا (۱۳۹۵). ارزیابی عملکرد واحدهای تصمیم‌گیرنده با استفاده از تحلیل پوششی داده‌های پنجره‌ای و درخت تصمیم. *نشریه فرایند مدیریت و توسعه*، ۲۹(۴)، ۲۱-۴۴.
- ظهری، مهدی، و افشارکاخمی، محمدعلی (۱۳۹۱). طراحی مدل پیش‌بینی ورشکستگی شرکت‌ها به وسیله شبکه‌های عصبی فازی (مطالعه موردی: شرکت‌های بورس اوراق بهادار تهران). *مهندسی مالی و مدیریت اوراق بهادار*، ۴(۱۳)، ۵۱-۷۲.
- قره‌پاشا، اکرم؛ عالی، صمد؛ بافنده‌زنده، علیرضا، و ایران‌زاده، سلیمان (۱۳۹۷). وفاداری مشتریان به خدمات بانکداری برخط. *نشریه فرایند مدیریت و توسعه*، ۳۲(۲)، ۳۱-۶۰.

محسنی، رضا، و رحیمیان، سمیرا (۱۳۹۷). بررسی عوامل موثر بر ورشکستگی با بهره‌گیری از کارایی به عنوان یک متغیر پیش‌بینی‌کننده مبتنی بر رهیافت پنل دیتا لاجیت. *اقتصاد مقداری*، ۱۵(۲)، ۱۱۱-۱۳۰. منصور، جهانگیر (۱۳۹۹). *قانون تجارت*. انتشارات دیدآور.

ناظمی اردکانی، مهدی (۱۳۹۴). بررسی تاثیر حاکمیت شرکتی و محافظه‌کاری بر توان پیش‌بینی مدل‌های ورشکستگی مبتنی بر شبکه‌های عصبی. *پژوهش‌های تجربی حسابداری*، ۵(۴)، ۱۱۳-۱۳۲.

ب) انگلیسی

- Alaka, H. A., Oyedele, L. O., Owolabi, H. A., Kumar, V., Ajayi, S. O., Akinade, O. O., & Bilal, M. (2018). Systematic Review of Bankruptcy Prediction Models: Towards a Framework for Tool Selection. *Expert Systems with Applications*, 94(1), 164-184.
- Antunes, F., Ribeiro, B., & Pereira, F. (2017). Probabilistic Modeling and Visualization for Bankruptcy Prediction. *Applied Soft Computing*, 60(1), 831-843.
- Arieshanti, I., Purwananto, Y., Ramadhani, A., Nuha, M. U., & Ulinuha, N. (2013). Comparative Study of Bankruptcy Prediction Models. *Telkomnika*, 11(3), 591-596.
- Barboza, F., Kimura, H., & Altman, E. (2017). Machine Learning Models and Bankruptcy Prediction. *Expert Systems with Applications*, 83(1), 405-417.
- Berg, D. (2007). Bankruptcy Prediction by Generalized Additive Models. *Applied Stochastic Models in Business and Industry*, 23(2), 129-143.
- Boratynska, K., & Grzegorzewska, E. (2018). Bankruptcy Prediction in the Agribusiness Sector: Lessons from Quantitative and Qualitative Approaches. *Journal of Business Research*, 89(1), 175-181.
- 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, Z., Chen, W., & Shi, Y. (2020). Ensemble Learning with Label Proportions for Bankruptcy Prediction. *Expert Systems with Applications*, 146.
- 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.
- Chou, C.-H., Hsieh, S.-C., & Qiu, C.-J. (2017). Hybrid Genetic Algorithm and Fuzzy Clustering for Bankruptcy Prediction. *Applied Soft Computing*, 56(1), 298-316.
- De Andrés, J., Landajo, M., & Lorca, P. (2012). Bankruptcy Prediction

- Models Based on Multinorm Analysis: An Alternative to Accounting Ratios. *Knowledge-Based Systems*, 30(1), 67-77.
- 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.
- Djebali, N., & Zaghdoudi, K. (2020). Threshold Effects of Liquidity Risk and Credit Risk on Bank Stability in the MENA Region. *Journal of Policy Modeling*. In press
- Du Jardin, P. (2015). Bankruptcy Prediction Using Terminal Failure Processes. *European Journal of Operational Research*, 242(1), 286-303.
- Du Jardin, P. (2016). A Two-Stage Classification Technique for Bankruptcy Prediction. *European Journal of Operational Research*, 254(1), 236-252.
- 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.
- Estévez, P. G., & Carballo, A. (2015). Qualitative Judgement in Public Credit Ratings: A Proposed Supporting Approach Using Self-Organising Maps (SOMs). *Cuadernos de Economía*, 38(108), 181-190.
- Fanelli, V., & Maddalena, L. (2020). A Nonlinear Dynamic Model for Credit Risk Contagion. *Mathematics and Computers in Simulation*, 174(1), 45-58.
- Fernandes, G. B., & Artes, R. (2016). Spatial Dependence in Credit Risk and Its Improvement in Credit Scoring. *European Journal of Operational Research*, 249(2), 517-524.
- Gepp, A., & Kumar, K. (2008). The Role of Survival Analysis in Financial Distress Prediction. *International Research Journal of Finance and Economics*, 16(16), 13-34.
- García, V., Marqués, A. I., & Sánchez, J. S. (2019). Exploring the Synergetic Effects of Sample Types on the Performance of Ensembles for Credit Risk and Corporate Bankruptcy Prediction. *Information Fusion*, 47(1), 88-101.
- Gordini, N. (2014). A Genetic Algorithm Approach for SMEs Bankruptcy Prediction: Empirical Evidence from Italy. *Expert Systems with Applications*, 41(14), 6433-6445.
- Grunert, J., Norden, L., & Weber, M. (2005). The Role of Non-Financial Factors in Internal Credit Ratings. *Journal of Banking & Finance*, 29(2), 509-531.
- He, Y., Xu, Z., & Gu, J. (2016). An Approach to Group Decision Making with Hesitant Information and Its Application in Credit Risk Evaluation of Enterprises. *Applied Soft Computing*, 43(1), 159-169.
- Huang, X., Liu, X., & Ren, Y. (2018). Enterprise Credit Risk Evaluation Based

- on Neural Network Algorithm. *Cognitive Systems Research*, 52(1), 317-324.
- Jabeur, S. B. (2017). Bankruptcy Prediction Using Partial Least Squares Logistic Regression. *Journal of Retailing and Consumer Services*, 36(1), 197-202.
- 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.
- Kim, M. J., & Kang, D. K. (2010). Ensemble with Neural Networks for Bankruptcy Prediction. *Expert Systems with Applications*, 37(4), 3373-3379.
- Kim, H.-J., Jo, N.-O., & Shin, K.-S. (2016). Optimization of Cluster-Based Evolutionary Undersampling for the Artificial Neural Networks in Corporate Bankruptcy Prediction. *Expert Systems with Applications*, 59(1), 226-234.
- Liang, D., Lu, C.-C., Tsai, C.-F., & Shih, G.-A. (2016). Financial Ratios and Corporate Governance Indicators in Bankruptcy Prediction: A Comprehensive Study. *European Journal of Operational Research*, 252(2), 561-572.
- Liu, C., Xie, J., Zhao, Q., Xie, Q., & Liu, C. (2019). Novel Evolutionary Multi-Objective Soft Subspace Clustering Algorithm for Credit Risk Assessment. *Expert Systems with Applications*, 138.
- Lyandres, E., & Zhdanov, A. (2013). Investment Opportunities and Bankruptcy Prediction. *Journal of Financial Markets*, 16(3), 439-476.
- Mai, F., Tian, S., Lee, C., & Ma, L. (2019). Deep Learning Models for Bankruptcy Prediction Using Textual Disclosures. *European Journal of Operational Research*, 274(2), 743-758.
- Nam, J. H., & Jinn, T. (2000). Bankruptcy Prediction: Evidence from Korean Listed Companies During the IMF Crisis. *Journal of International Financial Management & Accounting*, 11(3), 178-197.
- Piramuthu, S. (1999). Financial Credit-Risk Evaluation with Neural and Neurofuzzy Systems. *European Journal of Operational Research*, 112(2), 310-321.
- Pompe, P. P., & Bilderbeek, J. (2005). Bankruptcy Prediction: The Influence of the Year Prior to Failure Selected for Model Building and the Effects in a Period of Economic Decline. *Intelligent Systems in Accounting, Finance & Management: International Journal*, 13(2), 95-112.
- Psillaki, M., Tsolas, I. E., & Margaritis, D. (2010). Evaluation of Credit Risk Based on Firm Performance. *European Journal of Operational Research*, 201(3), 873-881.
- Qu, Y., Quan, P., Lei, M., & Shi, Y. (2019). Review of Bankruptcy

- Prediction Using Machine Learning and Deep Learning Techniques. *Procedia Computer Science*, 162(1), 895-899.
- Shi, Y., & Li, X. (2019). A Bibliometric Study on Intelligent Techniques of Bankruptcy Prediction for Corporate Firms. *Heliyon*, 5(12), 1-12.
- 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.
- Sironi, A., & Resti, A. (2007). *Risk Management and Shareholders' Value in Banking: From Risk Measurement Models to Capital Allocation Policies* (Vol. 417): John Wiley & Sons.
- Soares, J. O., Pina, J., Ribeiro, M., & Lopes, M. C. (2011). Quantitative VS. Qualitative Criteria for Credit Risk Assessment. *Frontiers in Finance and Economics*, 8(1), 69-87.
- Son, H., Hyun, C., Phan, D., & Hwang, H. J. (2019). Data Analytic Approach for Bankruptcy Prediction. *Expert Systems with Applications*, 138.
- Sousa, M. R., Gama, J., & Brandão, E. (2016). A New Dynamic Modeling Framework for Credit Risk Assessment. *Expert Systems with Applications*, 45(1), 341-351.
- Tobback, E., Bellotti, T., Moeyersoms, J., Stankova, M., & Martens, D. (2017). Bankruptcy Prediction for SMEs Using Relational Data. *Decision Support Systems*, 102(1), 69-81.
- 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(1), 977-984.
- Veganzones, D., & Séverin, E. (2018). An Investigation of Bankruptcy Prediction in Imbalanced Datasets. *Decision Support Systems*, 112(1), 111-124.
- 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.
- Volkov, A., Benoit, D. F., & Van den Poel, D. (2017). Incorporating Sequential Information in Bankruptcy Prediction with Predictors Based on Markov for Discrimination. *Decision Support Systems*, 98(1), 59-68.
- 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(1), 54-68.
- 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.
- 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.
- 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.
- Zhou, L., Lai, K. K., & Yen, J. (2014). 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.
- Zięba, M., Tomczak, S. K., & Tomczak, J. M. (2016). Ensemble Boosted Trees with Synthetic Features Generation in Application to Bankruptcy Prediction. *Expert Systems with Applications*, 58(1), 93-101.
- Zoričák, M., Gnip, P., Drotár, P., & Gazda, V. (2020). Bankruptcy Prediction for Small-and Medium-Sized Companies Using Severely Imbalanced Datasets. *Economic Modelling*, 84(1), 165-176.