



فصلنامه علمی پژوهشی دانش سرمایه‌گذاری
دوره ۱۵ / شماره ۱ (پیاپی ۵۸) / تابستان ۱۴۰۵
صفحه ۴۱۷ تا ۴۳۹

ارائه مدلی برای پیش‌بینی درماندگی مالی مبتنی بر یادگیری عمیق

اکرم کریم پور

دانشجوی دکترای مهندسی مالی، واحد دهقان دانشگاه آزاد اسلامی، دهقان، ایران.
Akram.karimpour1990@gmail.com

محسن اژدر

استادیار حسابداری، واحد شهرکرد دانشگاه آزاد اسلامی، شهرکرد، ایران. (نویسنده مسئول)
Azhdar.mohsen@gmail.com

سید محمدرضا داودی

دانشیار مدیریت، واحد دهقان دانشگاه آزاد اسلامی، دهقان، ایران.
smdavoodi@ut.ir

تاریخ دریافت: ۱۴۰۳/۰۲/۱۴ تاریخ پذیرش: ۱۴۰۳/۰۴/۲۳

چکیده

پیش‌بینی درماندگی مالی شرکت‌ها به دلیل تأثیر منفی مالی که درماندگی بر دارندگان بدهی مانند مؤسسات مالی دارد، به‌طور گسترده در امور مالی مورد مطالعه قرار می‌گیرد. در همین راستا، در تحقیق حاضر، مدلی جدید در رابطه با پیش‌بینی درماندگی مالی ارائه می‌شود که در آن از روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری استفاده خواهد شد. برای این منظور ابتدا ۳۴ نسبت مالی مرتبط با درماندگی مالی شرکت‌ها بر اساس روش کتابخانه‌ای شناسایی شد. سپس با استفاده از آزمون همبستگی پیرسون مشخص شد که ۲۵ شاخص دارای رابطه معناداری بوده و در نتیجه به‌عنوان معیارهای مورد استفاده در تجزیه و تحلیل انتخاب شد. در ادامه به محاسبه شاخص‌های شناسایی شده برای ۱۶۰ شرکت منتخب پذیرفته شده در بورس اوراق بهادار تهران طی دوره زمانی ۱۳۹۶ تا ۱۴۰۱ پرداخته شد. در نهایت نیز به تجزیه و تحلیل داده‌های گردآوری شده به روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری پرداخته شد. یافته‌های تحقیق در رابطه با پیش‌بینی درماندگی شرکت‌ها بر اساس روش یادگیری عمیق مبتنی بر الگوریتم فراابتکاری گرگ خاکستری، نشان داد که درصد موفقیت این مدل در پیش‌بینی درماندگی شرکت‌ها برابر با ۹۸/۳۳ درصد می‌باشد.

واژه‌های کلیدی: درماندگی مالی، روش یادگیری عمیق، الگوریتم فراابتکاری گرگ خاکستری.

۱- مقدمه

با توسعه جهانی شدن اقتصادی و بازار سرمایه، نگاه‌ها با رقابت و ریسک‌های بیشتر و پیچیده‌تر مواجه می‌شوند و فرصت‌های تجاری بیشتری را به دست می‌آورند. یکی از مهم‌ترین دلایل درماندگی این است که نگاه‌ها در فعالیت خود با خطرات مالی عظیمی روبرو هستند. در بیشتر موارد، بحران درماندگی شرکت نیز خود را به‌عنوان درماندگی مالی نشان می‌دهد. اگر مدیران نگاه‌ها نتوانند ریسک‌های مالی را شناسایی کنند و نشانه‌های ناراحتی مالی را زود تشخیص ندهند، ضررهای هنگفتی به خود وارد می‌کنند، به منافع سرمایه‌گذاران و مؤسسات مالی آسیب می‌رسانند و ثبات سیاسی و اقتصادی کشور و جهان را با مشکلات جدی مواجه می‌کنند؛ بنابراین، پیش‌بینی درماندگی مالی یک حوزه تحقیقاتی مهم در امور مالی شرکت و یک موضوع تحقیقاتی گسترده در حال انجام است (امتاج و امینی^۱، ۲۰۲۲).

در اوایل دهه ۱۹۳۰، محققان شروع به پیش‌بینی درماندگی مالی کردند. مطالعه پیشگام برای اولین بار توسط فیتزپاتریک^۲ ارائه شد و بیور^۳ مدل تک متغیره فیتزپاتریک را عمیقاً مطالعه کرد. به‌منظور بهبود مؤثر عملکرد مدل‌های تک متغیره، آلتمن^۴ ابتدا مدل تحلیل تفکیک چند متغیره، Z-Score را پیشنهاد کرد. متعاقباً، بسیاری از محققان مدل‌های تحلیل رگرسیون چندگانه، از جمله رگرسیون لجستیک و رگرسیون پروبیت را معرفی کردند. با این حال، این مدل‌های آماری الزامات سخت‌گیری برای داده‌ها دارند و داده‌ها باید مفروضات دقیقی مانند توزیع نرمال، نمونه بزرگ و اجتناب از هم خطی را برآورده کنند. در اواسط قرن بیستم، فناوری هوش مصنوعی ظهور کرد و محققان شروع به مطالعه مدل‌های پیش‌بینی درماندگی مالی هوشمندانه‌تر کردند. در مقایسه با روش‌های آماری سنتی، مدل‌های هوش مصنوعی مزایای منحصر به فرد خود را در مواجهه با داده‌های پیچیده مالی نشان می‌دهند. در حال حاضر، مطالعات مربوطه عمدتاً شامل کاربردها و بهبودهای درخت تصمیم^۵، ماشین بردار پشتیبانی^۶، شبکه عصبی^۷، یادگیری عمیق^۸ و استدلال مبتنی بر مورد^۹ می‌باشد (مارسو و ال مروانین^{۱۰}، ۲۰۲۰). در تحقیق حاضر، مدلی جدید در رابطه با پیش‌بینی درماندگی مالی ارائه می‌شود که در آن از روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری استفاده خواهد شد. بهره‌گیری از این مدل، می‌تواند نواقص مدل گذشته برای پیش‌بینی درماندگی مالی را مرتفع نماید. الگوریتم بهینه‌سازی گرگ خاکستری می‌تواند راهکاری برای مدل‌های پیش‌بینی به صورت کلی باشد و مختص پیش‌بینی درماندگی مالی نیست. بر اساس این توضیح، الگوریتم بهینه‌سازی گرگ خاکستری برای تنظیم پارامترهای پرسپترون چندلایه استفاده می‌شود تا پارامترهایی را تولید کند که عملکرد پرسپترون چندلایه را با دقت بیشتری ماکزیمم کند.

¹ Imteaj & Amini

² Fitzpatrick

³ Beaver

⁴ Altman

⁵ Decision Tree (DT)

⁶ Support Vector Machine (SVM)

⁷ Neural Network (NN)

⁸ Deep Learning (DL)

⁹ Case-Based Reasoning (CBR)

¹⁰ Marso & El Merouani

از این‌رو در این پژوهش به ارائه مدلی برای پیش‌بینی درماندگی مالی به روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری پرداخته می‌شود. ساختار مقاله حاضر به این صورت می‌باشد که در ادامه ضمن بیان ادبیات موضوع، به معرفی روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری پرداخته می‌شود. سپس روش تحقیق معرفی شده و به تجزیه و تحلیل داده‌ها پرداخته خواهد شد. در نهایت نیز جمع‌بندی و نتیجه‌گیری تحقیق ارائه می‌شود.

۲- ادبیات موضوع

پیش‌بینی درماندگی مالی شرکت‌ها به دلیل تأثیر منفی مالی که درماندگی بر دارندگان بدهی مانند مؤسسات مالی دارد، به‌طور گسترده در امور مالی مورد مطالعه قرار می‌گیرد؛ بنابراین، مؤسسات مالی، پیش از اعطای وام برای طرفین بالقوه، در تلاش برای کاهش چنین زیان‌هایی، احتمال ناراحتی طرفین بالقوه را مدل‌سازی می‌کنند (لیو و همکاران، ۲۰۲۲).

بنابراین یکی از راه‌های کمک به استفاده صحیح از فرصت‌های سرمایه‌گذاری و همچنین جلوگیری از اتلاف منابع کمک می‌نماید، پیش‌بینی درماندگی مالی است. در این رابطه، ابتدا با ارائه هشدارهای لازم، می‌توان شرکت‌ها را از وقوع درماندگی مالی آگاه کرد تا با توجه به این هشدارها اقدامات لازم را انجام دهند و ثانیاً سرمایه‌گذاران بتوانند بین فرصت‌های سرمایه‌گذاری مطلوب و نامطلوب برای سرمایه‌گذاری منابع خود تمایز قائل شوند (رحیمیان و همکاران، ۱۳۹۳). در سطح شهودی، واضح است که مهم است که بتوان احتمال درماندگی مالی را پیش‌بینی کرد. واضح است که تلاش‌ها برای انجام این کار به‌طور گسترده مورد استفاده قرار گرفته است. اگر فرض شود که هزینه (پیش‌فرض) درماندگی صفر است و حقوق ذینفعان (به‌عنوان مثال، طلبکاران، کارکنان، سهامداران) بدون هزینه قابل مذاکره مجدد است، ارزش شرکت می‌تواند مستقل از احتمال درماندگی مالی باشد. با این حال، حتی در این مورد، ممکن است ارزیابی احتمال درماندگی مالی از دیدگاه ذینفعان مهم باشد، زیرا توزیع سود مرتبط با سرمایه‌گذاری آنها را تعیین می‌کند. البته از نظر تجربی هزینه‌های درماندگی و مذاکره مجدد صفر نیست و ممکن است ارزش شرکت تحت تأثیر احتمال درماندگی مالی قرار گیرد (بیور و همکاران، ۲۰۱۱).

مطالعات قبلی نشان داده است که پیش‌بینی درماندگی یک کسب و کار یا سازمان بسیار مهم است. از آنجایی که شکست یک شرکت به‌طور مشخص با ویژگی‌ها و سبکه مالی شرکت ارتباط دارد، مدل‌سازی و پیش‌بینی احتمال درماندگی مالی شرکت‌ها یک کار ممکن و در عین حال ضروری است. تحقیقات قبلی بر توسعه مدل‌های آماری و یادگیری ماشینی برای پیش‌بینی مشکلات مالی متمرکز بوده است. محققان الگوهای هشداردهنده مشکلات اقتصادی را در بخش‌های مختلف شناسایی کرده‌اند، اما دقت آنها نیاز به بهبود دارد. بسیاری از الگوریتم‌ها با نادیده گرفتن مدت زمان واقعی، پیش‌بینی درماندگی مالی را به‌عنوان یک مسئله باینری در نظر می‌گیرند. همچنین، متغیرها و ویژگی‌ها ممکن است به هم مرتبط نباشند. بر این اساس و با توجه به مفاهیم مطرح‌شده و نقش ارزشمند

¹ Liu et al

² Beaver et al

و بی‌بدیل درماندگی مالی در توسعه صنایع و حفظ و افزایش سطح اشتغال پایدار کشور، پژوهش حاضر به طراحی مدل مبتنی بر یادگیری عمیق برای پیش‌بینی درماندگی مالی می‌پردازد.

۱-۲- پیش‌بینی درماندگی مالی

درماندگی مالی به ناتوانی شرکت در انجام تعهدات مالی خود به دلیل درآمد ناکافی اشاره دارد. قرار گرفتن در تنگنای مالی بر انواع مشاغل مختلف با تأثیر منفی شدید بر شرکت‌ها تأثیر می‌گذارد و ممکن است منجر به پیامدهای نامطلوب مختلفی مانند از دست دادن سرمایه‌گذاری، بیکاری و حتی کسری بودجه شود. پیش‌بینی درماندگی مالی، به‌عنوان ابزاری مؤثر برای شناسایی سیگنال‌های هشدار اولیه درماندگی مالی، نگرانی زیادی برای مدیران شرکت و سرمایه‌گذاران در مدیریت ریسک مالی دارد (چی و همکاران^۱، ۲۰۲۴).

درماندگی مالی شرکت‌ها و رویدادهای درماندگی مالی مطلوب نیستند زیرا هزینه‌های قانونی و مالی آنها بسیار زیاد است. به‌علاوه، این رویدادها هزینه‌های مورد انتظار برای مؤسسات مالی مانند بانک‌ها را افزایش می‌دهد تا در برابر خطر وقوع این رویدادها محافظت کنند. برای کاهش قرار گرفتن در معرض ریسک و دریافت علائم هشدار اولیه، سهامداران از جمله سرمایه‌گذاران، بانکداران و دولت‌ها فعالانه به دنبال راه‌حلی برای تجزیه و تحلیل و پیش‌بینی مؤثر درماندگی شرکت‌ها و رویدادهای درماندگی مالی هستند (ژائو و همکاران^۲، ۲۰۲۴).

پیش‌بینی دقیق درماندگی و ناراحتی‌های مالی در حال حاضر یک ورودی حیاتی برای فرآیندهای تصمیم‌گیری مهم در شرایط اقتصادی عادی است و حتی بیشتر از آن زمانی که جهان در معرض شوک‌های مهمی قرار می‌گیرد. سال ۲۰۲۰ شاهد تغییرات شدید در محیط سیاسی و اقتصادی جهانی و رویدادهایی مانند برگزیت، تشدید اختلافات تجاری جهانی، همه‌گیری کوید ۱۹؛ و انتخابات ریاست جمهوری ایالات متحده می‌باشد که قبلاً مشاغل را در سطح محلی یا جهانی در موقعیت چالش‌برانگیز بی‌سابقه‌ای قرار داده است (لی و همکاران^۳، ۲۰۲۳). در همین راستا، از زمان پیدایش بحث درماندگی مالی، پیش‌بینی درماندگی مالی شرکت‌ها در تکنیک‌های مدل‌سازی پیشرفت‌های چشمگیری داشته است. اولین مطالعه از نظر پیش‌بینی درماندگی مدرن را می‌توان در سال ۱۹۳۲ ردیابی کرد، زمانی که فیتزپاتریک (۱۹۳۲) با تجزیه و تحلیل ۲۰ جفت نسبت‌های حسابداری شرکت‌ها، راه موفقیت‌آمیزی را برای تمایز بین شرکت‌های درمانده و سالم ارائه کرد. از دهه ۱۹۶۰، چندین مدل آماری و احتمالی مبتنی بر حسابداری برای پیش‌بینی درماندگی مالی شرکت‌ها پیشنهاد شده‌اند (ژائو و همکاران^۴، ۲۰۲۲). علاوه بر این، چندین مطالعه بر شناسایی محرک‌های درماندگی و مشکلات مالی متمرکز شده‌اند. از یک طرف و دیگران بر طراحی روش‌شناسی برای انتخاب چنین محرک‌هایی تمرکز کردند (به‌عنوان مثال، تیان و یو^۵، ۲۰۱۷؛ اوتایاکومار

¹ Che et al

² Zhao et al

³ Li et al

⁴ Zhao et al

⁵ Tian & Yu

و همکاران^۱، ۲۰۲۰؛ کو و همکاران^۲، ۲۰۲۱)، علاوه بر این، جریانی از ادبیات علل عملکرد ضعیف مدل‌های پیش‌بینی درماندگی و مشکلات مالی مانند عدم تعادل نمونه داده‌ها را بررسی کرده‌اند (به‌عنوان مثال، وگانزونس و سورین^۳، ۲۰۱۸؛ زوریاک و همکاران^۴، ۲۰۲۰؛ شن و همکاران^۵، ۲۰۲۱).

روند تکامل مدل‌های پیش‌بینی درماندگی مالی نیز به این صورت بوده است که در ابتدا، با داده‌های کمیاب، این رشته بر تحلیل تفکیک‌کننده تنها با تعداد انگشت‌شماری از متغیرهای نسبت مالی متکی بود. سپس به رگرسیون لجستیک انتقال یافت. بعداً، تئوری پیش‌بینی‌های لاجیت از طریق مدل‌های مخاطرات اخلاقی^۶ و سایر بینش‌های حساس به زمان بهبود یافت. در سال‌های اخیر، با داده‌های بیشتر در دسترس، این زمینه به سمت الگوریتم‌های یادگیری ماشین تغییر کرده است، زیرا آنها مفروضات کمتری در مورد داده‌ها می‌کنند که می‌توانند با مجموعه‌های بزرگ‌تری از مشاهدات سر و کار داشته باشند و می‌توانند ده‌ها ویژگی را به‌طور هم‌زمان انتخاب کنند. همچنین این مدل‌ها میزان دقت بالایی را نشان داده‌اند (ماتوس و شاشا^۷، ۲۰۲۴). امروزه و در عصر ظهور فناوری‌های یادگیری ماشین و هوش مصنوعی، پیش‌بینی درماندگی و مشکلات مالی به سطح کاملاً جدیدی ارتقا یافته است، زیرا روش‌های بیشتر و بیشتری موفق به بهبود دقت پیش‌بینی از طریق ویژگی‌های طراحی مدل‌های جدید می‌شوند (جیانگ و همکاران^۸، ۲۰۲۳).

برای پیش‌بینی درماندگی مالی شرکت‌ها در مقاله حاضر، از روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری استفاده می‌شود که در ادامه به معرفی این روش پرداخته می‌شود.

۲-۲- الگوریتم گرگ خاکستری

میرجلیلی و همکاران^۹ (۲۰۱۴) الگوریتم بهینه‌سازی گرگ خاکستری (GWO) را در سال ۲۰۱۴ پیشنهاد کردند. با شبیه‌سازی سلسله‌مراتب جمعیت گرگ خاکستری و استراتژی شکار گرگ، الگوریتم به‌طور مکرر به دنبال راه‌حل بهینه می‌گردد. الگوریتم GWO دارای ویژگی‌های ساختار ساده، چند پارامتر است که نیاز به تنظیم دارند و پیاده‌سازی آسان که در میان آنها عوامل هم‌گرایی و مکانیسم‌های بازخورد اطلاعاتی وجود دارد که می‌توانند به‌صورت تطبیقی تنظیم شوند که می‌تواند به تعادل بین بهینه‌سازی محلی و جهانی دست یابد؛ بنابراین عملکرد خوبی در دقت و سرعت همگرایی دارد. هنگامی که از الگوریتم بهینه‌سازی گرگ خاکستری برای بهینه‌سازی تابع پیوسته استفاده می‌شود، تعداد گرگ‌ها بر روی N تنظیم می‌شود که در آن گرگ‌های α ، β ، δ به ترتیب به‌عنوان سطح اول، دوم و سوم تعریف می‌شوند و بقیه متعلق به پایین‌ترین سطح ω گرگ‌ها. بعد فضای جستجو روی d

¹ Uthayakumar et al

² Kou et al

³ Veganzones & Séverin

⁴ Zoričák et al

⁵ Shen et al

⁶ Hazard Models

⁷ Mattos & Shasha

⁸ Jiang et al

⁹ Mirjalili et al

تنظیم می‌شود و موقعیت گرگ پنجم در فضای d بعدی به صورت $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$ تعریف می‌شود. در فرآیند شکار گروه گرگ خاکستری، سطح پایین باید از سطح بالایی تبعیت کند. رفتار شکار گرگ‌ها شامل جستجو، نزدیک شدن، احاطه کردن، شکار، حمله و مراحل دیگر است. دو مرحله اصلی در فرآیند بهینه‌سازی، محاصره و شکار هستند. در مرحله احاطه، گرگ خاکستری موقعیت خود را با توجه به فاصله D از طعمه به روز می‌کند که می‌تواند با فرمول زیر بیان شود:

$$D = |C^* \cdot X_p(t) - X(t)| \quad (1)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (2)$$

که در آن t تعداد تکرارها را نشان می‌دهد. $X_p(t)$ موقعیت طعمه را نشان می‌دهد. $X(t)$ موقعیت گرگ خاکستری را در تکرار t نشان می‌دهد. A عامل همگرایی است. C^* یک ضریب ثابت است. با تنظیم این دو بردار، گرگ خاکستری می‌تواند به موقعیت‌های مختلف در اطراف طعمه برسد. فرمول زیر روش محاسبه آن را بیان می‌کند:

$$a = 2 - t / \text{Maxiter} \quad (3)$$

$$A = 2ar_1 - a \quad (4)$$

$$C^* = 2r_2 \quad (5)$$

که در آن $r_1, r_2 \in [1,0]$ بردارهای تصادفی هستند. t نشان‌دهنده تعداد تکرارها است. Maxiter حداکثر تعداد تکرار است. در مرحله شکار بعد از اینکه گرگ خاکستری طعمه را احاطه کرد شروع به شکار می‌کند که توسط α ، β ، δ هدایت می‌شود. ω موقعیت خود را با توجه به موقعیت α ، β ، δ به روز می‌کند. محاسبه به شرح زیر است:

$$\begin{cases} D_\alpha = |C_1 \cdot X_\alpha - X| \\ D_\beta = |C_2 \cdot X_\beta - X| \\ D_\delta = |C_3 \cdot X_\delta - X| \end{cases} \quad (6)$$

$$\begin{cases} X_1 = X_\alpha - A_1 \cdot D_\alpha \\ X_2 = X_\beta - A_2 \cdot D_\beta \\ X_3 = X_\delta - A_3 \cdot D_\delta \end{cases} \quad (7)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (8)$$

که در آن $D_\alpha, D_\beta, D_\delta$ نشان‌دهنده فاصله بین گرگ α, β, δ و گرگ ω . $X(t+1)$ مکان گرگ خاکستری پس از هر به‌روزرسانی است. با توجه به روش فوق، جواب بهینه هدف بهینه‌سازی با تکرار تا زمانی که شرط خاتمه برآورده شود، به دست می‌آید (سان و همکاران¹، ۲۰۲۳).

¹ Sun et al

پس از معرفی روش الگوریتم گرگ خاکستری که مورد توجه تحقیق حاضر می‌باشد، در ادامه به مروری بر مطالعات داخلی و خارجی انجام گرفته و مرتبط با موضوع تحقیق پرداخته می‌شود.

۳- پیشینه پژوهش

از جمله مرتبط‌ترین و به‌روزترین مطالعات داخلی مرتبط با موضوع تحقیق می‌توان به موارد زیر اشاره داشت: اسماعیلی و گوگردچیان (۱۳۹۶). در مطالعه‌ای به پیش‌بینی ورشکستگی مالی با استفاده از صورت جریان نقد: رهیافت شبکه عصبی مصنوعی پرداخته‌اند. بر اساس نتایج پژوهش، مدل شبکه عصبی با نسبت جریان نقدی عملیاتی به بدهی‌های جاری، نسبت پوشش جریان نقدی عملیاتی به بهره، نسبت بازده نقدی دارایی‌ها، نسبت کیفیت سود و نسبت آبی بیشترین قدرت پیش‌بینی را نسبت به ورشکستگی شرکت‌ها در ایران دارد.

خداکریمی و پیری (۱۳۹۶) در مطالعه‌ای به بررسی پیش‌بینی درماندگی مالی بر مبنای الگوی ترکیبی از اطلاعات حسابداری و بازار با رویکرد رگرسیون لجستیک پرداخته‌اند. با توجه به نتایج تحقیق می‌توان گفت که ترکیبی از اطلاعات حسابداری و بازار، توانایی پیش‌بینی کنندگی درماندگی شرکت‌ها را داشته و با توجه به بررسی تداوم فعالیت شرکت‌ها می‌تواند موجب ارتقاء کیفی تصمیم‌گیری سهامداران و ذینفعان گردد.

دباغ و شیخ بگلو (۱۳۹۹) در مطالعه‌ای به پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با روش‌های شبکه عصبی مصنوعی و مدل فولمر پرداخته‌اند. با استفاده از نتایج و مدل‌های ارائه شده در پژوهش می‌توان از مبتلا شدن شرکت‌ها به بحران مالی، ورشکستگی و همچنین پیامدهای آن، به‌طور مناسبی جلوگیری کرد. البته توجه این نکته نیز ضروری است که پس از پیش‌بینی می‌بایستی به ریشه‌یابی مسئله و پیگیری علل پرداخته شود.

ساده‌وند و همکاران (۱۴۰۱) تحقیقی با عنوان بررسی و مقایسه عملکرد مدل‌های مرسوم و ترکیبی در پیش‌بینی درماندگی مالی انجام داده‌اند. بر اساس نتایج تحقیق، مدل آلتمن در مقایسه با مدل ترکیبی و مرتون، قدرت پیش‌بینی مناسب‌تری برای شرکت‌های سالم و بدون کمک دارد. در همین حال، برای پیش‌بینی شرکت‌های پریشان، مدل مرتون و مدل ترکیبی بهتر از مدل آلتمن عمل کردند.

برگبید و همکاران (۱۴۰۱) در مطالعه‌ای به ارائه الگوی ترکیبی سه‌بعدی (مالی، اقتصادی، پایداری) در پیش‌بینی درماندگی مالی شرکت‌ها پرداخته‌اند. نتایج نشان داد الگوی ترکیبی سه‌بعدی (مالی، اقتصادی، پایداری) قدرت پیش‌بینی بالایی برای درماندگی دارد.

عالی و همکاران (۱۴۰۲) در مطالعه‌ای به ارائه مدل پیش‌بینی ریسک ورشکستگی مالی شرکت‌های بورسی و فرابورسی با بهره‌گیری از الگوریتم‌های یادگیری ماشین پرداخته‌اند. در این پژوهش ارائه پیش‌بینی ریسک ورشکستگی مالی شرکت‌های بورسی و فرابورسی با بهره‌گیری از الگوریتم‌های یادگیری ماشین صورت گرفته است که در آن هدف پیش‌بینی نهایی ریسک ورشکستگی مالی شرکت‌های بورسی و شرکت‌های فرابورسی است. یادگیری جمعی، حوزه‌ای از یادگیری ماشین هست که در آن به‌جای اینکه از یک مدل برای حل یک مسئله استفاده کنند، از چندین مدل به‌صورت ترکیبی استفاده می‌کنند تا توان تخمین خروجی مدل را بالاتر ببرند. هر

مدل با بهره‌گیری از ویژگی‌های بهینه مورد آموزش مجدد قرار می‌گیرد. در نتیجه دقت پیش‌بینی مدل یادگیری ماشین به روش Stacking که یکی از قوی‌ترین تکنیک‌های یادگیری جمعی است، برای پیش‌بینی ریسک ورشکستگی مالی از روش‌های مشابه بالاتر است.

امینی مهر و حکمت (۱۴۰۲) در مطالعه‌ای به بررسی قدرت شبکه عصبی پیچشی در پیش‌بینی درماندگی مالی پرداخته‌اند. در این پژوهش یک شبکه عصبی پیچشی به‌عنوان یک مدل یادگیری عمیق که داده‌های ۱۴ متغیر مرتبط با پیش‌بینی درماندگی مالی را در طول ۳ سال متوالی واکاوی می‌کند، برای پیش‌بینی درماندگی مالی مورد استفاده قرار گرفته است. در این راستا، به‌منظور جلوگیری از خطاهای احتمالی تعمیم‌پذیری، از روش K-fold برای نمونه‌گیری فرعی استفاده شده است که داده‌های ۳۰۰ نمونه را مورد بررسی قرار می‌دهد. در نهایت، با استفاده از آزمون ناپارامتریک Wilcoxon به بررسی معنی‌دار بودن اختلاف دقت پیش‌بینی ارائه شده میان مدل توسعه داده شده و مدل‌های پیشین پرداخته شده است. نتایج این پژوهش نشان می‌دهد مدل شبکه عصبی پیچشی به شکل معنی‌داری در سطح اطمینان ۹۵ درصد مدل‌های پیش‌بینی درماندگی سابق از جمله رگرسیون لجستیک و ماشین بردار پشتیبان را در دقت پیش‌بینی شکست می‌دهد.

لطفی و همکاران (۱۴۰۳) در مطالعه‌ای به پیش‌بینی درماندگی مالی با مدل ترکیبی (مطالعه موردی: شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران)، پرداخته‌اند. نتایج تحقیق نشان داد که مدل ترکیبی، قدرت توضیحی بهتری نسبت به مدل مرتون و مدل رگرسیون لجستیک باینری دارد و با وجود اینکه وجود متغیر احتمال نکول مدل مرتون باعث بهبود قدرت توضیحی مدل ترکیبی می‌شود ولی همچنان قدرت توضیحی مدل رگرسیون لجستیک باینری بهتر از مدل مرتون می‌باشد.

در بین مطالعات خارجی نیز می‌توان به موارد زیر اشاره داشت:

متین و همکاران^۱ (۲۰۱۹) در مطالعه‌ای به پیش‌بینی درماندگی مالی برای استفاده از روش یادگیری عمیق بخش‌های متن در گزارش‌های سالانه پرداخته‌اند. یافته‌های تحقیق نشان می‌دهد که داده‌های بدون ساختار، افزایش آماری قابل توجهی در عملکرد پیش‌بینی درماندگی مالی، به‌ویژه برای شرکت‌های بزرگی که پیش‌بینی‌های دقیق از اهمیت بالایی برخوردار است، فراهم می‌کند.

الحسنی و همکاران^۲ (۲۰۲۰) پژوهشی با عنوان مدل مبتنی بر یادگیری عمیق برای پیش‌بینی درماندگی مالی انجام دادند. در این مطالعه، یک الگوریتم بهینه‌سازی نهنگ تطبیقی با تکنیک یادگیری عمیق (AWOA-DL) برای ایجاد یک مدل جدید پیش‌بینی پریشانی مالی استفاده می‌شود. نتایج به برتری روش AWOA-DL بر سایر تکنیک‌های مقایسه شده با دستیابی به دقت متوسط ۹۵/۸٪ اشاره کرد.

سان و همکاران (۲۰۲۰) پژوهشی با عنوان پیش‌بینی درماندگی مالی چند کلاسه بر اساس ماشین‌های بردار پشتیبان ادغام شده با روش‌های تجزیه و همجوشی انجام دادند.

¹ Matin et al

² Elhoseny et al

لی و همکاران (۲۰۲۱) در مطالعه‌ای به بررسی یک رویکرد مبتنی بر یادگیری عمیق برای ساخت واژگان احساسات دامنه: مطالعه موردی در پیش‌بینی درماندگی مالی پرداخته‌اند. نتایج آزمایش نشان می‌دهد که مدل‌های مبتنی بر یادگیری عمیق می‌توانند به نتایج رضایت‌بخشی در تولید واژگان احساسات حوزه مالی چین دست یابند که عمدتاً چهار جنبه از کلمات احساسی، از جمله بازار سرمایه، بازار سهام، شرایط تجاری داخلی شرکت‌ها و سیاست را پوشش می‌دهد.

یو و لی^۱ (۲۰۲۳) در مطالعه‌ای به بررسی الگوی یادگیری گروهی مبتنی بر استدلال مبتنی بر مورد، برای پیش‌بینی مشکلات مالی با داده‌های از دست رفته پرداخته‌اند. نتایج مربوطه نشان می‌دهد که الگوی یادگیری مجموعه مبتنی بر استدلال مبتنی بر مورد پیشنهادی می‌تواند به‌طور مؤثر عملکرد انتساب را بهبود بخشد و استحکام عملکرد طبقه‌بندی را افزایش دهد که نشان می‌دهد که الگوی یادگیری گروه محور استدلال مبتنی بر مورد پیشنهادی می‌تواند به‌عنوان یک راه‌حل رقابتی برای پیش‌بینی درماندگی مالی استفاده شود.

چی و همکاران (۲۰۲۴) در مطالعه‌ای به بررسی پیش‌بینی درماندگی مالی با استفاده از داده‌های چندوجهی مبتنی بر روش یادگیری عمیق پرداخته‌اند. این تحقیق یک روش یادگیری عمیق دقیق و منظم برای پیش‌بینی درماندگی مالی با استفاده از داده‌های چندوجهی، از جمله شاخص‌های مالی، گزارش‌های جاری و شبکه‌های بین شرکتی پیشنهاد کرده است. به‌طور خاص، با در نظر گرفتن ناهمگونی در درون و بین روش‌ها، یک نظم‌دهی مبتنی بر آنتروپی مشروط طراحی و استفاده شده است. ارزیابی تجربی نشان می‌دهد که روش پیشنهادی به‌طور قابل‌توجهی از همه روش‌های معیار از نظر عملکرد پیش‌بینی و نمایش بهتر عمل می‌کند.

ماتوس و شاشا (۲۰۲۴) در مطالعه‌ای به بررسی پیش‌بینی ورشکستگی با اطلاعات مالی با کیفیت پایین پرداخته‌اند. آنها بیان داشته‌اند که ادبیات پیش‌بینی ورشکستگی شرکت‌ها به‌طور سنتی بر داده‌های شرکت‌های عمومی و حسابرسی شده متکی است. با این حال، اکثریت قریب به اتفاق شرکت‌ها در سرتاسر جهان خصوصی هستند و فاقد همان سطح نظارت بر صورت‌های مالی خود هستند. در نتیجه، این کسب‌وکارها معمولاً گزارش‌های حسابداری دقیق و شفاف کمتری تولید می‌کنند. مشکل تحقیق ما پرداختن به این شکاف است: سهامداران چگونه با این اطلاعات کمتر قابل‌اعتماد برخورد می‌کنند؟ با استفاده از مجموعه داده جدیدی از ۵۰۳ شرکت خصوصی که بین سال‌های ۲۰۰۷ تا ۲۰۲۰ برای سازمان‌دهی مجدد در برزیل درخواست داده‌اند، دریافتیم که نسبت‌های مالی نسبت به آنچه تحقیقات قبلی پیشنهاد می‌کرد، تأثیر بسیار کمتری بر توضیح نکول و ورشکستگی داشتند که تا حدی به دلیل محتوای اطلاعاتی پایین‌تر در صورت‌های حسابداری می‌باشد.

هیوانگ و همکاران^۲ (۲۰۲۴) در مطالعه‌ای با عنوان تشخیص با داده‌های چند بعدی ناقص: یک روش پیش‌بینی درماندگی مالی عمیق متغیر بیان داشته‌اند که تکثیر کلان داده‌ها از هر دو جنبه مالی و غیر مالی، پیش‌بینی مشکلات مالی مبتنی بر داده‌های چندگانه را شکوفا کرده است. با این حال، زمانی که دیدگاه‌های مختلف داده، به‌عنوان مثال، متن‌های گزارش، پست‌های انجمن و قضاوت‌های حقوقی، به‌طور مشترک مورد استفاده قرار

¹ Yu & Li

² Huang et al

می‌گیرند، چالش‌های مدل‌سازی، مانند ناهمگونی در توزیع و کامل بودن بین دیدگاه‌های داده، به‌ناچار ممکن است مطرح شود. برای این منظور، یک روش پیش‌بینی پریشانی مالی عمیق (VDFDP) پیشنهاد می‌شود. روش پیشنهادی از سه ماژول تشکیل شده است: یک ماژول رمزگذار مخصوص نما برای یادگیری یک نمایش نهفته برای هر نما، یک ماژول ترکیب دیدگاه برای یادگیری یک نمایش مشترک با انتقال دانش از همه نماها با در نظر گرفتن درجات مختلف کامل بودن و یک ماژول رمزگشای مشکلات مالی برای ترسیم نمایندگی مشترک به وضعیت پریشانی مالی. ارزیابی تجربی با استفاده از داده‌های شرکت فهرست شده چینی نشان می‌دهد که روش پیش‌بینی پریشانی مالی عمیق به‌طور قابل توجهی از همه روش‌های پیش‌بینی درماندگی مالی محک شده بهتر عمل می‌کند. این می‌تواند به‌طور مؤثرتری از داده‌های چند نمایش ناقص استفاده کند و مشکلات مالی را با دقت بیشتری پیش‌بینی کند.

بر اساس بررسی‌های صورت گرفته و مروری بر مطالعاتی که در فوق به آن‌ها اشاره شد، مشخص می‌شود که تاکنون تحقیقی مستقل درباره طراحی مدل مبتنی بر یادگیری عمیق برای پیش‌بینی درماندگی مالی با روش شبکه عصبی عمیق و الگوریتم گرگ خاکستری انجام نشده است و تحقیقات انجام شده که در پیشینه تحقیقات داخلی و خارجی به آن‌ها اشاره شده است هیچ‌کدام به ارائه این مدل پیش‌بینی نپرداخته‌اند. بر همین اساس، سؤال اصلی مطرح شده در تحقیق حاضر این می‌باشد که آیا روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری، رویکرد مناسبی برای پیش‌بینی درماندگی مالی شرکت‌ها می‌باشد؟

۴- روش پژوهش

با توجه به ادبیات موضوعی تحقیق در رابطه با درماندگی مالی شرکت‌ها، عوامل مؤثر بر درماندگی مالی و پیش‌بینی درماندگی مالی شرکت‌ها، به‌منظور ارزیابی و ارائه مدل جهت پیش‌بینی ورشکستگی شرکت‌ها، می‌توان از نسبت‌های مالی به‌عنوان ورودی‌های مدل پیش‌بینی استفاده کرد. در همین راستا، متغیرهای مستقل مدل، نسبت‌های مالی شرکت‌ها و متغیر وابسته مدل، نیز در نظر گرفتن وضعیت شرکت‌ها به لحاظ سالم بودن یا درمانده بودن از لحاظ مالی می‌باشد. بر اساس این مقدمه، متغیرهای مستقل در این تحقیق، سی و چهار مورد از مهم‌ترین نسبت‌های مالی شرکت‌ها می‌باشد که در جدول شماره (۱) به آن‌ها اشاره شده است:

جدول (۱): متغیرهای ورودی (مستقل) مدل جهت پیش‌بینی درماندگی مالی شرکت‌ها

ردیف	متغیر	نماد	نتیجه آزمون همبستگی پیرسون
۱	حاشیه سود خالص (سود خالص/درآمد)	X1	تأیید وجود رابطه معنادار
۲	حاشیه سود ناخالص (سود ناخالص/درآمد)	X2	تأیید وجود رابطه معنادار
۳	حاشیه سود عملیاتی (سود عملیاتی/درآمد)	X3	تأیید وجود رابطه معنادار
۴	حاشیه سود ناویژه (سود ناویژه/درآمد)	X4	تأیید وجود رابطه معنادار
۵	سود به سود ناویژه (سود/سود ناویژه)	X5	تأیید وجود رابطه معنادار

ردیف	متغیر	نماد	نتیجه آزمون همبستگی پیرسون
۶	بازده دارایی‌ها (سود خالص / کل دارایی‌ها)	X6	تأیید وجود رابطه معنادار
۷	بازده سرمایه (سود خالص / سرمایه)	X7	تأیید وجود رابطه معنادار
۸	بازده حقوق صاحبان سهام (سود خالص / حقوق صاحبان سهام)	X8	عدم تأیید وجود رابطه معنادار
۹	بازده سرمایه در گردش (سود خالص / سرمایه در گردش)	X9	عدم تأیید وجود رابطه معنادار
۱۰	بازده دارایی ثابت (سود خالص / دارایی ثابت)	X10	تأیید وجود رابطه معنادار
۱۱	سنجش سودمندی وام (بازده دارایی‌ها / بازده حقوق صاحبان سهام)	X11	تأیید وجود رابطه معنادار
۱۲	نسبت جاری (دارایی‌های جاری / بدهی‌های جاری)	X12	تأیید وجود رابطه معنادار
۱۳	نسبت آنی (دارایی‌های جاری بدون در نظر گرفتن موجودی کالا و پیش‌پرداخت‌ها / بدهی‌های جاری)	X13	تأیید وجود رابطه معنادار
۱۴	نسبت نقدینگی (دارایی‌های نقدی / بدهی‌های جاری)	X14	تأیید وجود رابطه معنادار
۱۵	نسبت دارایی‌های جاری (دارایی‌های جاری / کل دارایی‌ها)	X15	عدم تأیید وجود رابطه معنادار
۱۶	نسبت کفایت نقد (وجوه نقد عملیاتی / سود نقدی تقسیم شده، خرید دارایی‌های ثابت، بازپرداخت بدهی‌های بلندمدت، سود پرداختی بابت تسهیلات مالی)	X16	تأیید وجود رابطه معنادار
۱۷	نسبت گردش نقد (وجه نقد عملیاتی / بدهی‌های جاری)	X17	تأیید وجود رابطه معنادار
۱۸	سرمایه در گردش خالص (دارایی‌های جاری / بدهی‌های جاری)	X18	تأیید وجود رابطه معنادار
۱۹	دوره گردش موجودی کالا ((موجودی کالا * ۳۶۵) / بهای تمام شده کالای فروش رفته)	X19	تأیید وجود رابطه معنادار
۲۰	دوره وصول مطالبات ((متوسط حساب دریافتنی * ۳۶۵) / فروش)	X20	تأیید وجود رابطه معنادار
۲۱	نسبت کالا به سرمایه در گردش (موجودی کالا / سرمایه در گردش)	X21	تأیید وجود رابطه معنادار
۲۲	گردش سرمایه جاری (فروش / سرمایه در گردش)	X22	عدم تأیید وجود رابطه معنادار
۲۳	گردش دارایی‌های ثابت (فروش خالص / دارایی‌های ثابت)	X23	تأیید وجود رابطه معنادار
۲۴	گردش مجموع دارایی‌ها (فروش خالص / کل دارایی‌ها)	X24	تأیید وجود رابطه معنادار
۲۵	نسبت بدهی (کل بدهی‌ها / کل دارایی‌ها)	X25	تأیید وجود رابطه معنادار
۲۶	نسبت بدهی به ارزش ویژه (کل بدهی‌ها / ارزش ویژه ^۱)	X26	تأیید وجود رابطه معنادار

^۱ ارزش ویژه به عنوان ارزش دفتری دارایی یا حقوق صاحبان سهام شناخته می‌شود.

ردیف	متغیر	نماد	نتیجه آزمون همبستگی پیرسون
۲۷	نسبت بدهی بلندمدت به ارزش ویژه (بدهی‌های بلندمدت / ارزش ویژه)	X27	تأیید وجود رابطه معنادار
۲۸	نسبت بدهی جاری به ارزش ویژه (بدهی‌های جاری / ارزش ویژه)	X28	تأیید وجود رابطه معنادار
۲۹	نسبت مالکانه (جمع حقوق صاحبان سهام / کل دارایی‌ها)	X29	تأیید وجود رابطه معنادار
۳۰	نسبت پوشش بدهی (خالص درآمد عملیاتی / بدهی‌ها)	X30	عدم تأیید وجود رابطه معنادار
۳۱	نسبت پوشش بهره (سود عملیاتی / هزینه مالی)	X31	عدم تأیید وجود رابطه معنادار
۳۲	نسبت بار مالی وام (سود قبل از کسر بهره و مالیات / هزینه بهره پرداختی از اصل تسهیلات / ۱- نرخ مالیات)	X32	تأیید وجود رابطه معنادار
۳۳	هزینه‌های مالی به سود خالص (هزینه مالی / سود خالص)	X33	عدم تأیید وجود رابطه معنادار
۳۴	هزینه‌های مالی به سود عملیاتی (هزینه مالی / سود عملیاتی)	X34	عدم تأیید وجود رابطه معنادار

منبع: وانگ و همکاران (۲۰۱۷)

به‌منظور شناسایی شاخص‌های مالی موردنظر که قرار است وارد مدل شوند، ابتدا داده‌های ۱۶۰ شرکت منتخب طی سال‌های ۱۳۹۶ تا ۱۴۰۱ استخراج و با آزمون همبستگی پیرسون رابطه بین متغیرها بررسی و از ۳۴ نسبت مالی، ۲۵ نسبت که دارای رابطه معناداری بوده‌اند، انتخاب گردید.

جامعه آماری این پژوهش شامل شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران می‌باشد که از سال ۱۳۹۶ به بورس پیوسته باشند. در این پژوهش برای این که نمونه آماری یک نماینده مناسب از جامعه آماری موردنظر باشد، از روش حذف سیستماتیک استفاده شده و در صورتی که یک شرکت کلیه معیارها را احراز کرده باشد به‌عنوان یکی از شرکت‌های نمونه انتخاب شده است.

(۱) طی سال‌های ۱۳۹۶ الی ۱۴۰۱ تغییر سال مالی و توقف عملیات نداشته باشد.

(۲) صورت‌های مالی و یادداشت‌های توضیحی همراه شرکت‌ها در دوره زمانی مورد مطالعه در سایت‌های معتبر مربوط به بورس اوراق بهادار وجود داشته باشد.

(۳) قبل از سال ۱۳۹۶ در بورس اوراق بهادار تهران پذیرفته شده باشند.

(۴) وقفه آن‌ها بیش از ۳ ماه نباشد.


(۵) شرکت‌های موردنظر شامل شرکت‌های سرمایه‌گذاری واسطه‌گری مالی و نهادهای پولی نباشند.

بعد از مدنظر قرار دادن کلیه معیارهای بالا، تعداد ۱۶۰ شرکت به‌عنوان جامعه غربالگری شده باقیمانده است که تمامی آن‌ها به‌عنوان نمونه پژوهش انتخاب شده‌اند؛ بنابراین با توجه به بازه زمانی ۶ ساله پژوهش (۱۴۰۱-۱۳۹۶) مشاهدات به ۹۶۰ سال-شرکت (۶ سال \times ۱۶۰ شرکت) می‌رسد.

در این پژوهش اطلاعات موردنیاز مربوط به ادبیات پژوهش و مبانی نظری از روش کتابخانه‌ای و اسناد کاوی و پایگاه‌های علمی و مقالات داخلی و خارجی استفاده شده است. برای گردآوری داده‌های پژوهش نیز از صورت‌های مالی شرکت‌ها، بانک‌های اطلاعاتی سازمان بورس اوراق بهادار تهران و شرکت مدیریت فناوری بورس تهران، بانک‌های اطلاعاتی نرم‌افزار ره‌آورد نوین و همچنین گزارش‌ها و اطلاعیه‌های منتشره در شبکه کدال حسب مورد استفاده خواهد شد.

با توجه به اینکه روش‌های یادگیری به الگوریتمی بهینه‌ساز نیاز دارند، در این پژوهش از یکی از به‌روزترین آنها به نام «الگوریتم گرگ خاکستری» بهره برده می‌شود که در سال ۲۰۱۴ ابداع شده است. مدل پارامترها با استفاده از الگوریتم چند هدفه گرگ خاکستری تنظیم می‌شوند. گرگ‌های خاکستری موجوداتی هستند که به‌صورت نیمه دمکراسی زندگی می‌کنند و جایگاه هر گرگ در اجتماع آن‌ها پیداست. در این اجتماع گرگ رهبر، جانشینان او نیز سایر گرگ‌ها شناخته شده هستند. گرگ‌های خاکستری به‌صورت دسته جمعی زندگی و شکار می‌کند. در هر گروه از گرگ‌های خاکستری به‌طور متوسط بین ۷ الی ۱۲ گرگ وجود دارد. این دسته‌ها یکی از خطرناک‌ترین شکارچیان هستند. گرگ‌های خاکستری برای شکار کردن ابتدا دور طعمه حلقه زده و طعمه را محاصره می‌کند و به تنگ‌تر کردن حلقه محاصره شروع به خسته کردن طعمه می‌کنند سپس به‌صورت نوبتی و با دستور گرگ رهبر به طعمه حمله کرده و در نهایت طعمه را از پای درمی‌آورند.

همان‌گونه که بیان شد گرگ‌های خاکستری به‌صورت یک سلسله‌مراتب (با سخت‌گیری زیاد) زندگی می‌کنند. نمودار (۱)، ساختار سلسله‌مراتب گرگ‌های خاکستری را نشان می‌دهد.



نمودار (۱): الگوریتم بهینه‌سازی گرگ خاکستری

جفت آلفا [Alpha] که به‌عنوان رهبر گروه شناخته می‌شوند، تصمیم‌گیری درباره‌ی شکار، مکان خواب زمان بیدار شدن و... را بر عهده دارند. تصمیمات آلفا به کل گروه اعمال می‌شود. با این حال نوعی رفتار دموکراتیک نیز مشاهده می‌شود.

رده‌ی دوم در سلسله‌مراتب یک دسته، متعلق به گرگ‌های بتا [Beta] است. گرگ‌های بتا به آلفا در تصمیم‌گیری‌ها و سایر فعالیت‌های دسته کمک می‌کنند. این گرگ‌ها در مواقعی که آلفا بسیار پیر شده و یا می‌میرد، بهترین کاندید برای آلفا شدن هستند.

گرگ‌های با پایین‌ترین مقام، گرگ‌های امگا [Omega] هستند. این گروه از گرگ‌ها نقش پیش‌مرگ را در دسته بازی می‌کنند. آن‌ها باید مطیع تمام گرگ‌های دیگر باشند و همچنین آخرین گرگ‌هایی هستند که غذا می‌خورند. این‌طور به نظر می‌آید که امگاها اهمیت پایینی در دسته دارند، اما گاهی مشاهده شده است که در صورت از دست دادن امگاها، کل دسته دچار مشکلات و جنگ‌های داخلی می‌شود.

به گرگ‌هایی که در سلسله‌مراتب بالا ذکر نشده است، گرگ‌های دلتا [Delta] گفته می‌شود. گرگ‌های دلتا تحت فرمان آلفا و بتا بوده ولی نسبت به امگا برتری دارند. بر اساس این موارد الگوریتم گرگ خاکستری تبیین شد و معادلات ریاضی زیر در گرگ خاکستری به کار می‌رود.

همان‌طور که در بخش‌های پیشین اشاره شد، گرگ‌های خاکستری در طی فرآیند شکار، طعمه را محاصره می‌کنند. برای مدل کردن سازوکار شکار، از روابط زیر استفاده می‌شود:


$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (9)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (10)$$

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (11)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (12)$$

در روابط بالا t برابر تکرار الگوریتم بردارهای A و C ضرایب بردار مکان طعمه و X بردار مکان گرگ خاکستری است. a به صورت خطی و در طی تکرارها از مقدار ۲ به ۰ کاهش می‌یابد r_1 و r_2 بردارهای تصادفی در بازه $[0, 1]$ هستند. برای یک مسئله دو بعدی بردارها به صورت نمودار (۲) خواهد بود:



نمودار (۲): موقعیت بردارها در دو بعد و موقعیت بعدی آن‌ها

پس از معرفی روش تحقیق، در بخش بعدی به تجزیه و تحلیل داده‌ها پرداخته می‌شود.

۵- تجزیه و تحلیل داده‌ها

۵-۱- مراحل آنالیز آماری داده‌های ورودی

در مرحله اول، اطلاعات جمع‌آوری شده از شرکت‌های منتخب بورس اوراق بهادار تهران بر اساس ماده ۱۴۱ قانون تجارت (اطلاعات مربوط به سال مالی ۱۳۹۶ الی ۱۴۰۱) رتبه‌بندی گردید که ۱۰۲ شرکت موفق و ۵۸ شرکت درمانده را شامل می‌شد. در مرحله دوم، محاسبه متغیرهای پژوهش را شامل می‌شود (مرتب‌سازی، رتبه‌بندی و انجام محاسبات جهت به دست آوردن متغیرها از طریق صفحه گسترده اکسل صورت گرفته است). در مرحله سوم، داده‌ها جهت استفاده در روش فراابتکاری یادگیری عمیق مبتنی بر الگوریتم گرگ خاکستری به دیتا بیس در اکسس منتقل شده و در قالب جدول‌های مشخصی که به آن‌ها اشاره خواهد شد، نگهداری می‌شوند.

با توجه به اینکه الگوریتم باید تمامی حالت‌های ترکیبی ضرایب را در نظر گرفته و جهت استخراج ترکیب بهینه همه آن‌ها را مورد آزمایش قرار دهد، بنابراین لازم است کلیه زیرمجموعه‌های محض متغیرها مدنظر قرار بگیرد (زیرمجموعه‌های محض، به‌تمامی زیرمجموعه‌های یک مجموعه به غیر از خود مجموعه، می‌گویند). برای به دست آوردن زیرمجموعه‌های محض از رابطه‌ی زیر استفاده می‌شود:

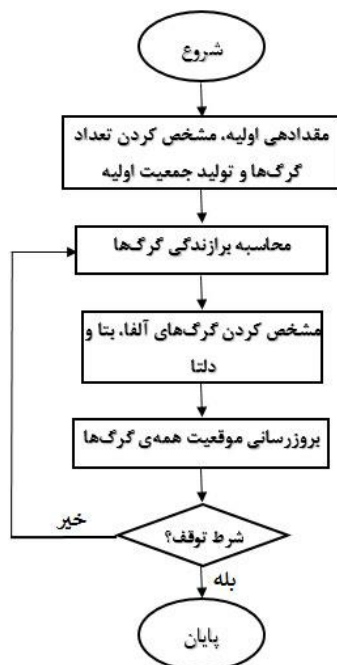
$$\text{تعداد زیرمجموعه‌های محض: } 2^n - 1$$

$$\text{تعداد زیرمجموعه‌های محض این پژوهش: } 2^{11} - 1 = 32768 - 1 = 32767$$

در واقع برای به دست آوردن حالت بهینه در فاز اول ۳۲۷۶۷ مرتبه متغیرهای فوق‌الذکر را با ضرایب آن‌ها ترکیب نموده‌ایم.

۵-۲- استخراج ضرایب متغیرها

برای آماده‌سازی داده‌ها جهت اجرای فاز اول برنامه، بایستی ضرایبی به متغیرها نسبت داد، در همین راستا با توجه به نتایج برآورد شده در قسمت اول پژوهش، به هر یک از ۱۰ متغیر مورد بررسی، یک ضریب نسبت داده شد؛ که این نسبت‌ها در حین اجرای اولیه‌ی الگوریتم، با توجه به ضریب چولگی متغیرهای مورد مطالعه تغییر پیدا می‌کند و نهایتاً ضرایب ابتدایی فاز اول آماده می‌گردد. پس از آماده شدن ضرایب، نوبت ورود به چرخه‌ی اجرای داده‌کاوی از طریق الگوریتم فراابتکاری گرگ خاکستری پرداخته می‌شود.



نمودار (۳): فلوچارت برنامه انتخاب ضرایب اولیه (داده‌کاوی)

الگوریتم گرگ خاکستری پارامترهایی دارند که باید مقدار آنها تعیین شود. گرگ‌های آلفا، بتا، گاما و امگا، پارامترهای الگوریتم گرگ خاکستری هستند. مقدار این پارامترها باید به نحوی تعیین شود که به جواب بهینه در مدل منجر شود. تعیین آنها توسط الگوریتم‌ها انجام می‌شود. این مقادیر در ابتدا به صورت تصادفی و توسط خود الگوریتم تعیین می‌شوند، سپس با هر تکرار مقادیر فوق تغییر می‌کنند تا به بهینه‌ترین جواب دست یابند. الگوریتم گرگ خاکستری مقادیر اولیه خود را به صورت تصادفی تعیین می‌کند. تعداد تکرار در الگوریتم گرگ خاکستری ۱۵۰ در نظر گرفته شده است. الگوریتم گرگ خاکستری در ۶۶ تکرار به مقادیری دست یافت که جواب بهینه را ارائه می‌کند. جواب بهینه پس از ۶۶ مرحله اجرا به صورت جدول (۲) به دست آمد:

جدول (۲): جواب بهینه متغیرها

ردیف	متغیر	شرح	پارامترهای بهینه
۱	X1	حاشیه سود خالص (سود خالص / درآمد)	-۱/۲۵۶
۲	X2	حاشیه سود ناخالص (سود ناخالص / درآمد)	۰/۳۵۸
۳	X3	حاشیه سود عملیاتی (سود عملیاتی / درآمد)	-۰/۶۸۵

ردیف	متغیر	شرح	پارامترهای بهینه
۴	X4	حاشیه سود ناویژه (سود ناویژه/درآمد)	-۰/۱۲۵
۵	X5	سود به سود ناویژه (سود/ سود ناویژه)	-۰/۳۲۰
۶	X6	بازده دارایی‌ها (سود خالص / کل دارایی‌ها)	-۰/۵۲۳
۷	X7	بازده سرمایه (سود خالص / سرمایه)	-۰/۰۱۲
۸	X10	بازده دارایی ثابت (سود خالص / دارایی ثابت)	-۰/۳۲۰
۹	X11	سنجش سودمندی وام (بازده دارایی‌ها / بازده حقوق صاحبان سهام)	-۰/۱۲۵
۱۰	X12	نسبت جاری (دارایی‌های جاری / بدهی‌های جاری)	-۱/۰۲۵
۱۱	X13	نسبت آنی (دارایی‌های جاری بدون در نظر گرفتن موجودی کالا و پیش‌پرداخت‌ها/ بدهی‌های جاری)	۰/۱۳۳
۱۲	X14	نسبت نقدینگی (دارایی‌های نقدی / بدهی‌های جاری)	۰/۳۰۷
۱۳	X17	نسبت گردش نقد (وجه نقد عملیاتی / بدهی‌های جاری)	-۰/۷۸۳
۱۴	X18	سرمایه در گردش خالص (دارایی‌های جاری / بدهی‌های جاری)	۰/۲۸۶
۱۵	X19	دوره گردش موجودی کالا ((موجودی کالا * ۳۶۵) / بهای تمام شده کالای فروش رفته)	-۰/۲۰۹
۱۶	X20	دوره وصول مطالبات ((متوسط حساب دریافتنی * ۳۶۵) / فروش)	-۰/۲۴۸
۱۷	X21	نسبت کالا به سرمایه در گردش (موجودی کالا / سرمایه در گردش)	-۰/۱۱۷
۱۸	X23	گردش دارایی‌های ثابت (فروش خالص / دارایی‌های ثابت)	۰/۳۵۵
۱۹	X24	گردش مجموع دارایی‌ها (فروش خالص / کل دارایی‌ها)	-۰/۰۸۸
۲۰	X25	نسبت بدهی (کل بدهی‌ها / کل دارایی‌ها)	-۰/۳۴۳
۲۱	X26	نسبت بدهی به ارزش ویژه (کل بدهی‌ها / ارزش ویژه)	-۰/۲۰۳
۲۲	X27	نسبت بدهی بلندمدت به ارزش ویژه (بدهی‌های بلندمدت / ارزش ویژه)	۱/۵۴۹
۲۳	X28	نسبت بدهی جاری به ارزش ویژه (بدهی‌های جاری / ارزش ویژه)	-۰/۲۸۲
۲۴	X29	نسبت مالکانه (جمع حقوق صاحبان سهام / کل دارایی‌ها)	-۰/۶۵۹
۲۵	X32	بازده حقوق صاحبان سهام (سود خالص / حقوق صاحبان سهام)	۰/۲۲۰

منبع: یافته‌های پژوهش

جهت اعتبارسنجی نتایج حاصل از پیش‌بینی درماندگی مالی بر اساس الگوریتم فرابتنکاری گرگ خاکستری در روش یادگیری عمیق، داده‌ها به دو دسته آموزشی و آزمایشی تقسیم شده، مدل با استفاده از داده‌های آموزشی ایجاد و سپس نتایج به دست آمده روی داده‌های آزمایشی آزمون می‌شود و در نهایت دقت مدل محاسبه می‌شود. برای ارزیابی روش‌های پیش‌بینی (اختلاف بین مقدار واقعی و مقدار پیش‌بینی شده) از شاخص میانگین مربعات خطا (MSE)، ریشه دوم مربعات خطا (RMSE)، ضریب همبستگی پیرسون (r) و ضریب تعیین (R2) استفاده شده است:

جدول (۳): نتایج حاصل از اعمال داده‌های آموزشی، اعتبارسنجی و ارزیابی الگوی فرابتکاری گرگ خاکستری

R2	r	RMSE	MSE	
۰/۸۵	۰/۶۸	۰/۰۴۲۵	۰/۰۰۱۵	کل داده‌ها
۰/۸۹	۰/۷۱	۰/۰۵۱۲	۰/۰۰۰۸	داده‌های آموزش
۰/۹۲	۰/۷۰	۰/۰۳۹۸	۰/۰۰۰۴	داده‌های آزمون
۰/۹۳	۰/۶۱	۰/۰۴۵۹	۰/۰۰۰۲	داده‌های اعتبارسنجی

منبع: یافته‌های پژوهش

با توجه به مقادیر کم MSE و RMSE به دست آمده و همچنین ضریب همبستگی مناسب بین خروجی مدل و خروجی هدف در جدول (۳)، الگوریتم فرابتکاری گرگ خاکستری در روش یادگیری عمیق به‌طور مطلوب قادر به مدل‌سازی داده‌ها می‌باشد.

پس از به دست آوردن جواب بهینه نوبت به مهم‌ترین قسمت پژوهش، یعنی تست مدل بر روی نسبت‌های مالی شرکت‌های موضوع پژوهش و آزمون فرضیه می‌رسد. نتایج آزمایش مدل یاد شده برای سال‌های اول، دوم و سوم به شرح جداول (۴) و (۵) به دست آمد:

جدول (۴): وضعیت شرکت‌ها بر اساس داده‌های گردآوری شده

تعداد کل شرکت‌ها	تعداد شرکت‌های ورشکسته	تعداد شرکت‌های سالم
۱۶۰	۵۸	۱۰۲

منبع: یافته‌های پژوهش

جدول (۵): نتایج آزمون درماندگی برای شرکت‌های مورد بررسی

تعداد کل شرکت‌ها	تعداد شرکت‌های سالم	تعداد شرکت‌های ورشکسته	درصد موفقیت مدل
۱۶۰	۱۰۱	۵۹	۹۸/۳۳٪

منبع: یافته‌های پژوهش

نتایج مربوط به پیش‌بینی درماندگی شرکت‌ها بر اساس الگوریتم فرابتکاری گرگ خاکستری در روش یادگیری عمیق، نشان داد که درصد موفقیت این مدل در پیش‌بینی درماندگی شرکت‌ها برابر با ۹۸/۳۳ درصد می‌باشد به عبارت دیگر الگوریتم گرگ خاکستری توانسته ۱۰۱ شرکت از ۱۰۵ شرکت سالم را به‌درستی پیش‌بینی کند که نشان‌دهنده قدرت پیش‌بینی‌کنندگی ۹۸/۳۳ درصد می‌باشد.

۶- نتیجه‌گیری

هدف اصلی پژوهش حاضر ارائه مدلی برای پیش‌بینی درماندگی مالی مبتنی بر یادگیری عمیق در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران طی دوره زمانی ۱۳۹۶ تا ۱۴۰۱ می‌باشد. به‌منظور شناسایی شاخص‌های مالی موردنظر که قرار است وارد مدل شوند، ابتدا داده‌های ۱۶۰ شرکت منتخب طی سال‌های ۱۳۹۶ تا ۱۴۰۱ استخراج و با آزمون همبستگی پیرسون رابطه بین متغیرها بررسی و از ۳۴ نسبت مالی، ۲۵ نسبت که دارای رابطه معناداری بوده‌اند، انتخاب گردید. سپس و به‌منظور آنالیز آماری داده‌های ورودی، در مرحله اول، اطلاعات جمع‌آوری شده از شرکت‌های منتخب بورس اوراق بهادار تهران بر اساس ماده ۱۴۱ قانون تجارت رتبه‌بندی گردید که ۱۰۲ شرکت موفق و ۵۸ شرکت درمانده را شامل می‌شد. در مرحله دوم، محاسبه متغیرهای پژوهش را شامل می‌شود (مرتب‌سازی، رتبه‌بندی و انجام محاسبات جهت به دست آوردن متغیرها از طریق صفحه گسترده اکسل صورت گرفته است). در مرحله سوم، داده‌ها جهت استفاده در روش فرابتکاری یادگیری عمیق مبتنی بر الگوریتم گرگ خاکستری به دیتا بیس در اکسس منتقل شد. الگوریتم گرگ خاکستری مقادیر اولیه خود را به‌صورت تصادفی تعیین می‌کند. تعداد تکرار در الگوریتم گرگ خاکستری ۱۵۰ در نظر گرفته شده است. الگوریتم گرگ خاکستری در ۶۶ تکرار به مقادیری دست یافت که جواب بهینه را ارائه می‌کند. سپس و جهت اعتبارسنجی نتایج حاصل از پیش‌بینی درماندگی مالی بر اساس الگوریتم فرابتکاری گرگ خاکستری در روش یادگیری عمیق، داده‌ها به دو دسته آموزشی و آزمایشی تقسیم شده، مدل با استفاده از داده‌های آموزشی ایجاد و سپس نتایج به دست آمده روی داده‌های آزمایشی آزمون می‌شود و در نهایت دقت مدل محاسبه شد. نتایج به دست آمده در این قسمت نشان داد که با توجه به مقادیر کم MSE و RMSE به دست آمده و همچنین ضریب همبستگی مناسب بین خروجی مدل و خروجی هدف، الگوریتم فرابتکاری گرگ خاکستری در روش یادگیری عمیق به‌طور مطلوب قادر به مدل‌سازی داده‌ها می‌باشد. در نهایت نیز نتایج مربوط به پیش‌بینی درماندگی شرکت‌ها بر اساس الگوریتم فرابتکاری گرگ خاکستری در روش یادگیری عمیق، نشان داد که درصد موفقیت این مدل در پیش‌بینی درماندگی شرکت‌ها برابر با ۹۸/۳۳ درصد می‌باشد به عبارت دیگر الگوریتم گرگ خاکستری توانسته ۱۰۱ شرکت از ۱۰۵ شرکت سالم را به‌درستی پیش‌بینی کند که نشان‌دهنده قدرت پیش‌بینی‌کنندگی ۹۸/۲۳ درصد می‌باشد.

این نتیجه‌گیری با یافته‌های به دست آمده توسط اسماعیلی و گوگردچیان (۱۳۹۶)، دباغ و شیخ بگلو (۱۳۹۹)، رحیمی و همکاران (۱۴۰۱)، متین و همکاران (۲۰۱۹)، الحسنی و همکاران (۲۰۲۰) و لی و همکاران (۲۰۲۱) مطابقت دارد که نشان داده‌اند روش‌های مبتنی رویکرد یادگیری عمیق و استفاده از الگوریتم‌های فرابتکاری می‌تواند دقت بالایی در پیش‌بینی قدرت درماندگی مالی شرکت‌ها داشته باشد.

در این رابطه استدلال می‌شود که درماندگی مالی یکی از موضوعات مهم در بازارهای مالی بوده و می‌تواند در مدل تصمیم‌گیری سرمایه‌گذاران وارد شود تا از طریق آن، سرمایه‌گذاران بتوانند به تجزیه و تحلیل وضعیت مالی موارد سرمایه‌گذاری پرداخته و با مشخص شدن سطح درماندگی مالی آنها، به‌طور جداگانه و با اطمینان در مورد سرمایه‌گذاری در موقعیت مناسب تصمیم‌گیری کنند. با گسترش روزافزون شرکت‌های سهامی و پدیدار شدن بحران‌های مالی شدید در ابعاد خرد کلان اقتصادی، مالکان و ذینفعان بنگاه‌ها به دنبال ایجاد پوششی برای مصون

کردن خود در مقابل این‌گونه مخاطرات بوده‌اند و این موضوع آنها را به استفاده از مدل‌های پیش‌بینی‌کننده برای ارزیابی توان مالی شرکت‌ها حساس و آگاه نموده است. مدل‌های تشخیص درماندگی یکی از مهم‌ترین ابزارها در تعیین وضعیت مالی شرکت‌ها می‌باشد. از این رو، همواره سرمایه‌گذاران در پی روش‌هایی برای پیش‌بینی درماندگی مالی شرکت‌ها برای اخذ تصمیمات صحیح مالی هستند که بر اساس یافته‌های تحقیق حاضر، روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری به‌عنوان یک روش مناسب برای پیش‌بینی درماندگی مالی شرکت‌های بورس تهران پیشنهاد می‌شود. نتایج این تحقیق نشان داد که الگوریتم‌های فراابتکاری روش یادگیری عمیق مبتنی بر الگوریتم گرگ خاکستری، به دلایلی چون تبیین درصد بیشتری از واقعیات مسئله، وابسته نبودن به شکل تابع برآوردی (خطی، غیرخطی و ...) در روش‌های رگرسیونی، عدم وابستگی به استقلال خطی متغیرهای مستقل از یکدیگر و همچنین وابسته نبودن به پیش‌فرض نرمال بودن توزیع متغیرهای مستقل و وابسته از نتایج دقیق‌تر و قابل‌اتکاتری نسبت به روش‌های کلاسیک مبتنی بر رگرسیون برخوردار است. اثبات توانمندی مدل‌های پایه و ترکیبی مذکور در پیش‌بینی درماندگی مالی بر اساس متغیرهای درون شرکتی، دلالت بر تأیید صاحب‌نظران معتقد به تأثیر اطلاعات حسابداری در ارزیابی تداوم فعالیت بنگاه اقتصادی و تشخیص ریسک درماندگی مالی بوده و هم‌راستا با نتایج اغلب تحقیقات انجام شده در زمینه پیش‌بینی درماندگی مالی با استفاده از اطلاعات مالی مانند تحقیقات مرتبط با ابداع مدل‌های کلاسیک ورشکستگی و نیز مطالعات اشاره شده در بخش پیشینه این تحقیق می‌باشد.

با توجه به این که نتایج تحقیق نشان داد که روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری می‌تواند به‌عنوان یک الگوی بهینه در پیش‌بینی درماندگی مالی شرکت‌های بورس تهران مورد استفاده قرار گیرد، بر همین اساس پیشنهاد می‌گردد که:

- سازوکاری در بازار بورس طراحی شود که از الگوی بهینه در پیش‌بینی درماندگی مالی شرکت‌های بورس تهران به‌عنوان یک مکانیسم هشداردهنده ورشکستگی شرکت‌ها استفاده گردد و در صورت احتمال وقوع درماندگی مالی شرکت، به مدیران شرکت‌ها و همچنین سهامداران هشدار دهد.
- مدیران شرکت‌ها همواره سعی نمایند از تکنیک‌های مناسب همانند روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری در پیش‌بینی احتمال وقوع درماندگی مالی شرکت‌های خود استفاده نمایند تا بتوانند شرایط شرکت را بهتر و دقیق‌تر ارزیابی کنند.
- تحلیل‌گران در بازار سرمایه، سهامداران شرکت‌ها و سایر ذینفعان بازار همواره استفاده از روش یادگیری عمیق مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری در پیش‌بینی احتمال درماندگی مالی شرکت‌ها را مدنظر داشته باشند.

فهرست منابع

اسماعیلی، سهیلا، گوگردچیان، احمد. (۱۳۹۶). پیش‌بینی ورشکستگی مالی با استفاده از صورت جریان نقد: رهیافت شبکه عصبی مصنوعی. مدیریت فرهنگ‌سازمانی، ۱۵(۴)، ۸۷۹-۹۰۱.

امینی مهر، امین و حکمت، هانیه (۱۴۰۲). قدرت شبکه عصبی پیچشی در پیش‌بینی درماندگی مالی، فصلنامه راهبرد مدیریت مالی، دوره: ۱۱، شماره: ۲.

برگ بید، احمد، جعفری، علی، صالح نژاد، سید حسن. (۱۴۰۱). ارائه الگوی ترکیبی سه‌بعدی (مالی، اقتصادی، پایداری) در پیش‌بینی درماندگی مالی شرکت‌ها. فصلنامه پژوهش‌های حسابداری مالی و حسابرسی، ۱۳(۵۱)، ۱۰۵-۱۳۲.

خداکریمی، پری، پیری، پرویز. (۱۳۹۶). پیش‌بینی درماندگی مالی بر مبنای الگوی ترکیبی از اطلاعات حسابداری و بازار با رویکرد رگرسیون لجستیک. مطالعات تجربی حسابداری مالی، ۱۴(۵۵)، ۱۴۵-۱۶۸.

دباغ، رحیم، شیخ بگلو، سیما. (۱۳۹۹). پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با روش‌های شبکه عصبی مصنوعی و مدل فولمر. مجله توسعه و سرمایه، ۵(۲)، ۱۵۳-۱۶۸.

رحیمیان، نظام الدین، توکل نیا، اسماعیل، قربانی، محمود. (۱۳۹۳). درماندگی مالی و تاخیر گزارش حسابرسی، نشریه دانش حسابداری مالی، ۱(۲)، ۷۷-۵۷.

ساده‌وند، محمدجواد، نیکومرام، هاشم، قالیباف اصل، حسن، فلاح شمس، میرفیض. (۱۴۰۱). بررسی و مقایسه عملکرد مدل‌های متعارف و ترکیبی در پیش‌بینی درماندگی مالی. تحقیقات مالی، ۲۴(۲)، ۲۱۴-۲۳۵.

عالی، محسن و میرعبابایی، سید علیرضا و فرجیان، نیما (۱۴۰۲). ارائه مدل پیش‌بینی ریسک ورشکستگی مالی شرکت‌های بورسی و فرابورسی با بهره‌گیری از الگوریتم‌های یادگیری ماشین، فصلنامه تحلیل بازار سرمایه، دوره: ۲، شماره: ۲.

لطفی، بهناز، بحری ثالث، جمال، جبارزاده کنگرلویی، سعید، حیدری، مهدی. (۱۴۰۳). پیش‌بینی درماندگی مالی با مدل ترکیبی (مطالعه موردی: شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران). دانش سرمایه‌گذاری، ۱۳۱(۵۰)، ۳۴۹-۳۷۰.

Beaver, W.H., Correia, M., & McNichols, M.F. (2011), Financial Statement Analysis and the Prediction of Financial Distress. Foundations and Trends® in Accounting 5(2): 99-173. <http://dx.doi.org/10.1561/1400000018>

Che, W., Wang, Zh., Jiang, C., & Zoynul Abedin, M. (2024). Predicting financial distress using multimodal data: An attentive and regularized deep learning method, Information Processing & Management 61(4): 103703.

Elhoseny, M., Metawa, N., Sztano, G., El-hasnony, I.M. (2020). Deep Learning-Based Model for Financial Distress Prediction. Ann Oper Res 25: 1-23.

Fitzpatrick, P.J. (1932). A comparison of the ratios of successful industrial enterprises with those of failed companies, The Certified Public Accountant 12: 727-731.

Huang, Y., Wang, Zh., & Jiang, C. (2024). Diagnosis with incomplete multi-view data: A variational deep financial distress prediction method, Technological Forecasting and Social Change 201: 123269.

Imteaj, H., & Amini, H. (2022). Leveraging asynchronous federated learning to predict customer's financial distress. Intelligent Systems with Applications 14: 200064.

Jiang, C., Ma, L., Wang, Zh., & Chen, B. (2023). Financial distress prediction using the Q&A text of online interactive platforms, Electronic Commerce Research and Applications 61(4): 101292.

- Kou, G., Xu, Y., Peng, Y., Shen, F., Chen, Y., Chang, K., & Kou, S. (2021). Bankruptcy prediction for SMEs using transactional data and two-stage multiobjective feature selection, *Decision Support Systems* 140: 113429.
- Le, T., Vo, B., Fujita, H., Nguyen, N.T., & Baik, S.W. (2019). A fast and accurate approach for bankruptcy forecasting using squared logistics loss with GPU-based extreme gradient boosting, *Information Sciences* 494: 294-310.
- Li, Sh., Shi, W., Wang, J., & Zhou, H. (2021). A Deep Learning-Based Approach to Constructing a Domain Sentiment Lexicon: a Case Study in Financial Distress Prediction. *Information Processing & Management* 58(5):102673.
- Li, Z., Crook, J., Andreeva, G., & Tang, Y. (2023). Predicting the risk of financial distress using corporate governance measures, *Pacific-Basin Finance Journal* 68: 101334.
- Liu, W., Fan, H., Xia, M., & Pang, C. (2022). Predicting and interpreting financial distress using a weighted boosted tree-based tree. *Engineering Applications of Artificial Intelligence* 116: 105466.
- Marso, S., & El Merouani, M. (2020). Predicting financial distress using hybrid feedforward neural network with cuckoo search algorithm. *Procedia Computer Science* 170: 1134-1140.
- Matin, R., Hansen, C., Hansen, Ch., & Mølgaard, P. (2019). Predicting distresses using deep learning of text segments in annual reports. *Expert Systems with Applications* 132: 199-208.
- Mattos, E.D.S., & Shasha, D. (2024). Bankruptcy prediction with low-quality financial information, *Expert Systems with Applications* 237(P1): 121418.
- Mirjalili, S., Mirjalili, S.M., Lewis, A. (2014). Grey Wolf Optimizer. *Advances in Engineering Software* 69: 46-61.
- Shen, F., Liu, Y., Wang, R., & Zhou, W. (2021). A dynamic financial distress forecast model with multiple forecast results under unbalanced data environment, *Knowledge-Based Systems* 192(4): 105365.
- Sun, Y., Zhang, J., & Zhang, Y. (2023). Echo State Neural Network Based on an Improved Gray Wolf Algorithm Predicts Porosity through Logging Data, *ACS Omega* 2023 8(23): 21182–21194.
- Tian, S., & Yu, Y. (2017). Financial ratios and bankruptcy predictions: An international evidence, *International Review of Economics & Finance* 51: 510-526.
- Uthayakumar, J., Metawa, N., Shankar, K., & Lakshmanprabu, S.K. (2020). Financial crisis prediction model using ant colony optimization, *International Journal of Information Management* 50: 538-556.
- Veganzones, D., & Séverin, E. (2018). An investigation of bankruptcy prediction in imbalanced datasets, *Decision Support Systems* 112: 111-124
- Yu, L., & Li, M. (2023). A case-based reasoning driven ensemble learning paradigm for financial distress prediction with missing data. *Applied Soft Computing* 137: 110163.
- Zhao, J., Ouenniche, J., & De Smedt, J. (2024). Survey, classification and critical analysis of the literature on corporate bankruptcy and financial distress prediction, *Machine Learning with Applications* 15: 100527.
- Zhao, Sh., Xu, K., Wang, Zh., Liang, Ch., Lu, W., & Chen, B. (2022). Financial distress prediction by combining sentiment tone features, *Economic Modelling* 106: 105709.
- Zhou, F., Fu, L., Li, Zh., & Xu, J. (2022). The recurrence of financial distress: A survival analysis. *International Journal of Forecasting* 38(3): 1100-1115.
- Zoričák, M., Gnip, P., Drotár, P., & Gazda, V. (2020). Bankruptcy prediction for small- and medium-sized companies using severely imbalanced datasets *Economic Modelling* 84: 165-176.

A Model for Predicting Financial Distress Based on Deep Learning

Akram Karimpour

PhD Student in Financial Engineering, Dehaghan Branch, Islamic Azad University, Dehaghan, Iran.

Mohsen Azhdar

Assistant Professor of Accounting, shahrekord Branch, Islamic Azad University, shahrekord, Iran.

Sayed Mohammad Reza Davoodi

Associate Professor of Management, Dehaghan Branch, Islamic Azad University, Dehaghan, Iran.

Abstract

Predicting corporate financial distress has been extensively studied in finance due to the negative financial impacts that distress has on debt holders, such as financial institutions. In this context, the present study introduces a novel model for predicting financial distress using a deep learning method based on the Grey Wolf Optimization (GWO) algorithm. To this end, 34 financial ratios associated with corporate financial distress were initially identified through a library research method. Subsequently, using Pearson correlation analysis, it was determined that 25 indicators had a significant relationship and were thus selected as the criteria for further analysis. The identified indicators were then calculated for 160 selected companies listed on the Tehran Stock Exchange during the period 2017 to 2022. Finally, the collected data were analyzed using a deep learning method based on the Grey Wolf Optimization metaheuristic algorithm. The research findings on predicting corporate distress based on the deep learning method with the GWO algorithm indicated that the success rate of this model in predicting corporate financial distress was 98.33%.

Keywords: Financial Distress, Deep Learning Method, Grey Wolf Optimization Metaheuristic Algorithm.

