



Prediction of Financial Distress in Companies Listed on the Tehran Stock Exchange Using Support Vector Machines (SVM) Optimized by Metaheuristic Algorithms

Hossein Sabzevari^{1*}, Kiana Rostami²

¹ M.A. in Financial Management, University of Isfahan, Isfahan, Iran (Corresponding Author) Corresponding Author's Email: H.sabzevari@gmail.com

² M.A. in Financial Management, University of Isfahan, Isfahan, Iran

ARTICLE INFO

Article history:

Received:10/10/2025

Received in revised form:17/10/2025

Accepted:11/11/2025

Available online:06/12/2025

Keywords:

Financial Distress Prediction
Support Vector Machine (SVM)
Metaheuristic Algorithms
Particle Swarm Optimization
Tehran Stock Exchange

ABSTRACT

Financial distress is considered one of the most critical stages preceding corporate bankruptcy, and its timely identification can prevent substantial losses for investors, creditors, and other stakeholders. In recent years, machine learning techniques have been widely employed in financial distress prediction due to their strong capability to extract complex patterns from financial data. In this study, the Support Vector Machine (SVM) is utilized as one of the most effective classification algorithms. Given the sensitivity of SVM performance to its tuning parameters, metaheuristic algorithms are employed to optimize the model parameters. The primary objective of this research is to develop a hybrid model based on SVM and metaheuristic optimization algorithms to improve the accuracy of financial distress prediction for companies listed on the Tehran Stock Exchange (TSE). Previous studies have demonstrated that the application of metaheuristic algorithms, such as the Genetic Algorithm (GA), Particle Swarm Optimization (PSO), and Ant Colony Optimization (ACO), can significantly enhance the performance of SVM models and improve prediction accuracy.

Article Type: Research Paper



©Authors

Cite: Sabzevari,H and Rostami,K . (2025). Prediction of Financial Distress in Companies Listed on the Tehran Stock Exchange Using Support Vector Machines (SVM) Optimized by Metaheuristic Algorithms. *Journal of Intelligent Financial Management*, 1(3), 37-54.

Journal of Intelligent Financial Management,
2025, Vol. 1, No.3, pp.37-54.

Publish by:

Tolou-e Binish-e Ayandeh Scientific Institute

<https://doi.org/10.25843/JIFM.2025.8563.21599>



پیش‌بینی درماندگی مالی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران با استفاده از ماشین‌های بردار پشتیبان (SVM) بهینه‌شده با الگوریتم‌های فراابتکاری

حسین سبزواری^{۱*}، کیانا رستمی^۲

۱- کارشناسی ارشد مدیریت مالی، دانشگاه اصفهان، اصفهان، ایران (نویسنده مسئول)، ایمیل نویسنده مسئول: H.sabzevari@gmail.com

۲- کارشناسی ارشد مدیریت مالی، دانشگاه اصفهان، اصفهان، ایران

اطلاعات مقاله

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۴/۰۷/۱۸

تاریخ بازنگری: ۱۴۰۴/۰۷/۲۵

تاریخ پذیرش: ۱۴۰۴/۰۸/۲۰

تاریخ انتشار: ۱۴۰۴/۰۹/۱۵

کلیدواژه‌ها:

درماندگی مالی

ماشین بردار پشتیبان

الگوریتم‌های فراابتکاری

پیش‌بینی ورشکستگی

بورس اوراق بهادار تهران

چکیده

درماندگی مالی یکی از مهم‌ترین مراحل پیش از ورشکستگی شرکت‌ها محسوب می‌شود که شناسایی به‌موقع آن می‌تواند از بروز زیان‌های گسترده برای سرمایه‌گذاران، اعتباردهندگان و سایر ذی‌نفعان جلوگیری کند. در سال‌های اخیر، روش‌های یادگیری ماشین به دلیل توانایی بالا در استخراج الگوهای پیچیده از داده‌های مالی، به‌طور گسترده در حوزه پیش‌بینی درماندگی مالی مورد استفاده قرار گرفته‌اند. در این پژوهش، از ماشین بردار پشتیبان به‌عنوان یکی از کارآمدترین الگوریتم‌های طبقه‌بندی استفاده شده است. با توجه به حساسیت عملکرد SVM نسبت به پارامترهای تنظیمی، از الگوریتم‌های فراابتکاری برای بهینه‌سازی پارامترهای مدل بهره گرفته می‌شود. هدف اصلی این مطالعه، ارائه مدلی ترکیبی مبتنی بر SVM و الگوریتم‌های فراابتکاری به‌منظور افزایش دقت پیش‌بینی درماندگی مالی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران است. نتایج مطالعات پیشین نشان می‌دهد که استفاده از الگوریتم‌های فراابتکاری نظیر الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و الگوریتم کلونی مورچگان می‌تواند عملکرد مدل SVM را به‌طور قابل توجهی بهبود بخشد و دقت پیش‌بینی را افزایش دهد.

نوع مقاله: پژوهشی



© نویسندگان

استناد: سبزواری، حسین و رستمی، کیانا. (۱۴۰۴). پیش‌بینی درماندگی مالی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران با استفاده از ماشین‌های بردار پشتیبان (SVM) بهینه‌شده با الگوریتم‌های فراابتکاری. *مدیریت مالی هوشمند*، ۱(۳)، ۳۷-۵۴.

نشریه مدیریت مالی هوشمند، ۱۴۰۴، دوره ۱، شماره ۳، صفحه ۳۷-۵۴.

ناشر: موسسه علمی طلوع بینش آینده

<https://doi.org/10.25843/JIFM.2025.8563.21599>

۱- مقدمه

در دنیای رقابتی و پویای امروز، بقای سازمان‌ها و شرکت‌های تجاری بیش از هر زمان دیگری به توانایی آن‌ها در حفظ سلامت مالی و مدیریت بهینه منابع وابسته است. شرکت‌ها به‌عنوان مهم‌ترین بازیگران اقتصادی در بازارهای سرمایه، نقش تعیین‌کننده‌ای در رشد اقتصادی، اشتغال‌زایی، توسعه سرمایه‌گذاری و تخصیص بهینه منابع ایفا می‌کنند. از این‌رو، هرگونه اختلال در وضعیت مالی شرکت‌ها می‌تواند آثار نامطلوبی بر ذی‌نفعان مختلف از جمله سهامداران، اعتباردهندگان، سرمایه‌گذاران، کارکنان و حتی کل اقتصاد کشور بر جای گذارد. یکی از مهم‌ترین چالش‌هایی که شرکت‌ها در طول چرخه حیات خود با آن مواجه می‌شوند، پدیده در ماندگی مالی است؛ وضعیتی که در آن شرکت به تدریج توانایی ایفای تعهدات مالی خود را از دست داده و در صورت تداوم این شرایط، احتمال ورشکستگی و خروج از بازار افزایش می‌یابد (بیور، ۲۰۲۴). از این‌رو، شناسایی زود هنگام نشانه‌های در ماندگی مالی و پیش‌بینی آن پیش از وقوع بحران، همواره از موضوعات مهم و مورد توجه پژوهشگران، مدیران مالی و نهادهای نظارتی بوده است.

در ماندگی مالی معمولاً به‌عنوان مرحله‌ای پیش از ورشکستگی تعریف می‌شود که در آن شرکت با مشکلات نقدینگی، کاهش سودآوری، افزایش بدهی‌ها و ناتوانی در بازپرداخت تعهدات خود مواجه می‌شود. این وضعیت اگرچه الزاماً به ورشکستگی منجر نمی‌شود، اما بیانگر کاهش توان عملیاتی و مالی شرکت است و می‌تواند پیامدهای گسترده‌ای برای ذی‌نفعان ایجاد کند. مطالعات انجام‌شده نشان می‌دهد که بسیاری از شرکت‌ها پیش از اعلام رسمی ورشکستگی، برای چندین سال نشانه‌هایی از ضعف مالی و کاهش عملکرد را از خود بروز می‌دهند؛ از این‌رو، توسعه مدل‌هایی که بتوانند این نشانه‌ها را در مراحل اولیه شناسایی کنند، از اهمیت ویژه‌ای برخوردار است (آلتمن، ۲۰۲۵). اهمیت این موضوع در بازارهای سرمایه نوظهور، از جمله بورس اوراق بهادار تهران، به دلیل نوسانات اقتصادی، محدودیت‌های مالی، تحریم‌های بین‌المللی و عدم قطعیت‌های محیطی دوچندان است. پیش‌بینی در ماندگی مالی از دهه ۱۹۶۰ میلادی به یکی از حوزه‌های مهم پژوهشی در ادبیات مالی و حسابداری تبدیل شده است. نخستین مطالعات در این زمینه عمدتاً بر تحلیل نسبت‌های مالی استوار بودند. بیور (۱۹۶۶) نشان داد که برخی نسبت‌های مالی می‌توانند توانایی مناسبی در تفکیک شرکت‌های سالم از شرکت‌های در معرض شکست داشته باشند. پس از آن، آلتمن (۱۹۶۸) با معرفی مدل معروف Z-Score مبتنی بر تحلیل ممیزی چندگانه، گام مهمی در توسعه مدل‌های پیش‌بینی ورشکستگی برداشت. این مدل برای سال‌های طولانی به‌عنوان یکی از مهم‌ترین ابزارهای ارزیابی وضعیت مالی شرکت‌ها مورد استفاده قرار گرفت. در ادامه، پژوهشگرانی نظیر اولسون (۱۹۸۰) از روش‌های آماری پیشرفته‌تری همچون رگرسیون لجستیک برای پیش‌بینی در ماندگی مالی بهره گرفتند و تلاش کردند محدودیت‌های مدل‌های سنتی را کاهش دهند.

با وجود موفقیت نسبی مدل‌های آماری کلاسیک، این مدل‌ها با محدودیت‌هایی مواجه هستند. مهم‌ترین محدودیت آن‌ها وابستگی به فروض آماری خاص، حساسیت نسبت به توزیع داده‌ها و ناتوانی در مدل‌سازی روابط پیچیده و غیرخطی میان متغیرهای مالی است. در عمل، رفتار مالی شرکت‌ها تحت تأثیر عوامل متعددی قرار دارد که روابط میان آن‌ها غالباً غیرخطی، پویا و پیچیده است. بنابراین، استفاده از روش‌هایی که بتوانند این پیچیدگی‌ها را به‌خوبی شناسایی و مدل‌سازی کنند، ضروری به نظر می‌رسد (هسپه و همکاران، ۲۰۱۴). در این راستا، پیشرفت‌های چشمگیر در حوزه هوش مصنوعی و یادگیری ماشین، فرصت‌های جدیدی را برای توسعه مدل‌های دقیق‌تر پیش‌بینی در ماندگی مالی فراهم کرده است. یادگیری ماشین یکی از شاخه‌های مهم هوش مصنوعی است که بر توسعه الگوریتم‌هایی تمرکز دارد که قادرند بدون برنامه‌ریزی صریح، از داده‌ها الگو بیاموزند و تصمیم‌گیری کنند. در سال‌های اخیر، الگوریتم‌های یادگیری ماشین به دلیل قدرت بالا در تحلیل داده‌های حجیم و کشف روابط پنهان میان متغیرها، کاربرد گسترده‌ای در حوزه مالی پیدا کرده‌اند. پیش‌بینی قیمت سهام، مدیریت ریسک اعتباری، ارزیابی عملکرد شرکت‌ها و پیش‌بینی ورشکستگی از جمله مهم‌ترین حوزه‌های کاربرد این فناوری محسوب می‌شوند (کیم، ۲۰۲۱). مطالعات مختلف نشان داده‌اند که الگوریتم‌های یادگیری ماشین در بسیاری از موارد عملکرد بهتری نسبت به مدل‌های آماری سنتی ارائه می‌دهند و قادرند با دقت بیشتری وضعیت مالی شرکت‌ها را پیش‌بینی کنند. در میان روش‌های مختلف یادگیری ماشین، ماشین بردار پشتیبان به‌عنوان یکی از قدرتمندترین و پرکاربردترین الگوریتم‌های طبقه‌بندی شناخته می‌شود. این الگوریتم نخستین بار توسط واپنیک و همکاران معرفی شد و به دلیل توانایی بالا در حل مسائل طبقه‌بندی و رگرسیون، مورد توجه گسترده محققان قرار گرفت (واپنیک، ۲۰۱۹). مبنای اصلی عملکرد ماشین بردار پشتیبان، یافتن یک ابرصفحه بهینه است که بتواند داده‌های متعلق به کلاس‌های مختلف را با بیشترین حاشیه ممکن از یکدیگر جدا کند. این ویژگی موجب می‌شود که مدل از

قابلیت تعمیم مناسبی برخوردار بوده و در مواجهه با داده‌های جدید عملکرد مطلوبی ارائه دهد. همچنین، استفاده از توابع هسته‌ای امکان مدل‌سازی روابط غیرخطی را فراهم می‌کند و این مزیت، ماشین بردار پشتیبان را به ابزاری مناسب برای مسائل پیچیده مالی تبدیل کرده است. مطالعات متعددی کارایی بالای ماشین بردار پشتیبان را در پیش‌بینی در ماندگی مالی تأیید کرده‌اند. نتایج این پژوهش‌ها نشان می‌دهد که SVM در مقایسه با روش‌هایی نظیر تحلیل ممیزی چندگانه، رگرسیون لجستیک و حتی برخی شبکه‌های عصبی مصنوعی، از دقت پیش‌بینی بالاتری برخوردار است (مین و لی، ۲۰۱۵). با این حال، یکی از چالش‌های اساسی در استفاده از ماشین بردار پشتیبان، انتخاب مناسب پارامترهای مدل است. پارامترهایی نظیر ضریب جریمه (C) و پارامتر هسته (γ) تأثیر مستقیمی بر عملکرد نهایی مدل دارند و انتخاب نامناسب آن‌ها می‌تواند منجر به بیش‌برازش یا کم‌برازش شود. به همین دلیل، تعیین مقادیر بهینه این پارامترها یکی از مهم‌ترین مراحل طراحی مدل محسوب می‌شود.

در سال‌های اخیر، پژوهشگران برای حل این مسئله به استفاده از الگوریتم‌های فراابتکاری روی آورده‌اند. الگوریتم‌های فراابتکاری مجموعه‌ای از روش‌های جستجوی هوشمند هستند که با الهام از پدیده‌های طبیعی، زیستی و اجتماعی طراحی شده‌اند و قابلیت بالایی در حل مسائل پیچیده بهینه‌سازی دارند (بلوم و راولی، ۲۰۰۳). این الگوریتم‌ها برخلاف روش‌های سنتی جستجو، قادرند فضای پاسخ را به صورت گسترده بررسی کرده و از گرفتار شدن در بهینه‌های محلی جلوگیری کنند. از جمله شناخته‌شده‌ترین الگوریتم‌های فراابتکاری می‌توان به الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات، الگوریتم کلونی مورچگان و الگوریتم گرگ خاکستری اشاره کرد.

ترکیب ماشین بردار پشتیبان با الگوریتم‌های فراابتکاری طی سال‌های اخیر به یکی از رویکردهای نوین و مؤثر در پیش‌بینی در ماندگی مالی تبدیل شده است. در این رویکرد، الگوریتم فراابتکاری وظیفه جستجوی مقادیر بهینه پارامترهای SVM را بر عهده دارد و بدین ترتیب عملکرد مدل بهبود می‌یابد. نتایج مطالعات متعدد نشان داده است که مدل‌های ترکیبی مبتنی بر SVM و الگوریتم‌های فراابتکاری در مقایسه با مدل پایه SVM از دقت، پایداری و قابلیت تعمیم بیشتری برخوردار هستند (میرجلیلی، ۲۰۱۴؛ کندی و ابره‌ارت، ۱۹۹۵). این مزیت به‌ویژه در مسائل مالی که داده‌ها دارای پیچیدگی و عدم قطعیت بالایی هستند، اهمیت بیشتری پیدا می‌کند.

در بازار سرمایه ایران نیز با توجه به افزایش تعداد شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، رشد حجم معاملات و اهمیت تصمیم‌گیری آگاهانه سرمایه‌گذاران، نیاز به توسعه مدل‌های دقیق پیش‌بینی در ماندگی مالی بیش از گذشته احساس می‌شود. شرایط اقتصادی کشور، نوسانات نرخ ارز، تغییرات تورمی، محدودیت‌های مالی و تحولات سیاسی از جمله عواملی هستند که می‌توانند وضعیت مالی شرکت‌ها را تحت تأثیر قرار دهند و احتمال بروز در ماندگی مالی را افزایش دهند. در چنین شرایطی، بهره‌گیری از فناوری‌های نوین داده‌کاوی و یادگیری ماشین می‌تواند نقش مؤثری در شناسایی زود هنگام شرکت‌های در معرض خطر ایفا کند.

بر این اساس، پژوهش حاضر با هدف ارائه یک چارچوب هوشمند برای پیش‌بینی در ماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، از ماشین بردار پشتیبان بهینه شده با الگوریتم‌های فراابتکاری استفاده می‌کند. انتظار می‌رود که این رویکرد ضمن افزایش دقت پیش‌بینی، بتواند ابزار کارآمدی برای مدیران، سرمایه‌گذاران، تحلیلگران مالی و نهادهای نظارتی فراهم آورد و از این طریق به ارتقای کارایی بازار سرمایه و کاهش ریسک تصمیم‌گیری کمک کند.

۲- مبانی نظری و پیشینه پژوهش

۲-۱ در ماندگی مالی

در ماندگی مالی یکی از مهم‌ترین مفاهیم در حوزه مدیریت مالی، حسابداری و اقتصاد بنگاه‌ها محسوب می‌شود که در دهه‌های اخیر به دلیل افزایش نوسانات اقتصادی، پیچیده‌تر شدن محیط کسب‌وکار و تشدید رقابت در بازارهای مالی، توجه گسترده‌ای را به خود جلب کرده است. در ادبیات مالی، در ماندگی مالی به وضعیتی اطلاق می‌شود که در آن یک شرکت به تدریج توانایی خود را برای ایفای تعهدات مالی کوتاه‌مدت و بلندمدت از دست می‌دهد و با مشکلاتی نظیر کمبود نقدینگی، افزایش هزینه‌های تأمین مالی، کاهش سودآوری و افت ارزش بازار مواجه می‌شود. این وضعیت معمولاً پیش از وقوع ورشکستگی رخ می‌دهد و می‌تواند به عنوان یک هشدار اولیه برای ذی‌نفعان شرکت تلقی شود. به بیان دیگر، در ماندگی مالی مرحله‌ای میانی میان عملکرد عادی شرکت و ورشکستگی کامل است که در صورت شناسایی به‌موقع و اتخاذ تصمیمات اصلاحی مناسب، امکان بازگشت شرکت به شرایط مطلوب وجود دارد (التمان و هوتچکیس، ۲۰۱۷).

اهمیت درماندگی مالی از آن جهت است که آثار آن تنها محدود به خود شرکت نیست، بلکه می‌تواند پیامدهای گسترده‌ای برای سهامداران، اعتباردهندگان، کارکنان، مشتریان، تأمین‌کنندگان و حتی کل اقتصاد به همراه داشته باشد. هنگامی که یک شرکت وارد مرحله درماندگی مالی می‌شود، اعتماد سرمایه‌گذاران نسبت به آینده آن کاهش یافته و ارزش سهام شرکت در بازار افت می‌کند. همچنین بانک‌ها و سایر مؤسسات مالی تمایل کمتری به اعطای تسهیلات جدید خواهند داشت و هزینه تأمین مالی شرکت افزایش می‌یابد. در چنین شرایطی، کاهش سرمایه‌گذاری، افت تولید، تعدیل نیروی انسانی و کاهش توان رقابتی شرکت از جمله پیامدهای محتمل خواهد بود (روس، وسترفیلد و جردن، ۲۰۲۲). از این‌رو، شناسایی زودهنگام درماندگی مالی می‌تواند نقش مهمی در کاهش خسارات اقتصادی و افزایش کارایی تصمیمات مدیریتی ایفا کند.

اگرچه مفاهیم درماندگی مالی و ورشکستگی در بسیاری از مطالعات به جای یکدیگر استفاده شده‌اند، اما این دو مفهوم از نظر ماهوی تفاوت‌های مهمی با یکدیگر دارند. ورشکستگی معمولاً یک وضعیت حقوقی و قانونی است که پس از ناتوانی کامل شرکت در ایفای تعهدات خود و طی مراحل قانونی اعلام می‌شود، در حالی که درماندگی مالی مفهومی اقتصادی و عملیاتی است که پیش از ورشکستگی رخ می‌دهد و بیانگر ضعف تدریجی عملکرد مالی شرکت است (بیور، ۱۹۶۶). به عبارت دیگر، تمامی شرکت‌های ورشکسته پیش از ورشکستگی وارد مرحله درماندگی مالی می‌شوند، اما همه شرکت‌های درمانده الزاماً ورشکسته نخواهند شد؛ زیرا برخی از آن‌ها از طریق اصلاح ساختار مالی، افزایش سرمایه، تجدید ساختار بدهی‌ها یا بهبود عملکرد عملیاتی می‌توانند از بحران خارج شوند.

یکی از مهم‌ترین چالش‌های مرتبط با درماندگی مالی، شناسایی عوامل و نشانه‌های بروز آن است. پژوهش‌های مختلف نشان داده‌اند که درماندگی مالی معمولاً با مجموعه‌ای از علائم هشداردهنده همراه است که در صورت پایش مستمر می‌توانند به عنوان ابزارهای پیش‌بینی مورد استفاده قرار گیرند. کاهش مستمر سودآوری، افت بازده دارایی‌ها، کاهش جریان‌های نقدی عملیاتی، افزایش نسبت بدهی، کاهش سرمایه در گردش، افزایش هزینه‌های مالی و کاهش ارزش بازار سهام از جمله مهم‌ترین شاخص‌های مرتبط با درماندگی مالی هستند (کاراپتو و همکاران، ۲۰۲۱). این شاخص‌ها معمولاً چند سال پیش از وقوع بحران مالی قابل مشاهده‌اند و به همین دلیل نقش مهمی در توسعه مدل‌های پیش‌بینی درماندگی مالی دارند. بررسی ادبیات پژوهش نشان می‌دهد که مطالعات علمی مرتبط با پیش‌بینی درماندگی مالی سابقه‌ای بیش از پنج دهه دارد. یکی از نخستین پژوهشگران این حوزه، ویلیام بیور بود که در سال ۱۹۶۶ با استفاده از تحلیل نسبت‌های مالی نشان داد برخی نسبت‌های

حسابداری قادرند شرکت‌های موفق را از شرکت‌های در معرض شکست تفکیک کنند. پس از آن، ادوارد آلتمن در سال ۱۹۶۸ مدل مشهور Z-Score را معرفی کرد که یکی از مهم‌ترین و پرکاربردترین مدل‌های پیش‌بینی ورشکستگی محسوب می‌شود. این مدل بر مبنای تحلیل ممیزی چندگانه طراحی شد و توانست با ترکیب چند نسبت مالی، احتمال ورشکستگی شرکت‌ها را با دقت قابل قبولی پیش‌بینی کند (آلتمن، ۱۹۶۸). موفقیت این مدل موجب شد تا پژوهشگران بسیاری در دهه‌های بعد به توسعه مدل‌های جدید پیش‌بینی درماندگی مالی بپردازند.

در سال‌های اخیر، تغییرات گسترده در محیط کسب‌وکار و پیچیده‌تر شدن ساختارهای مالی شرکت‌ها باعث شده است که روش‌های سنتی پیش‌بینی درماندگی مالی با محدودیت‌هایی مواجه شوند. بسیاری از مدل‌های کلاسیک مبتنی بر فرض خطی بودن روابط میان متغیرها هستند، در حالی که واقعیت‌های اقتصادی نشان می‌دهد عوامل مؤثر بر درماندگی مالی دارای روابط پیچیده، غیرخطی و پویا هستند. علاوه بر این، افزایش حجم داده‌های مالی و ظهور فناوری‌های نوین اطلاعاتی، نیاز به استفاده از روش‌های پیشرفته‌تر را بیش از پیش آشکار کرده است (ژانگ، ۲۰۲۰). در پاسخ به این نیاز، استفاده از تکنیک‌های داده‌کاوی، هوش مصنوعی و یادگیری ماشین در حوزه پیش‌بینی درماندگی مالی رشد چشمگیری داشته است. یکی از عوامل مهمی که احتمال وقوع درماندگی مالی را افزایش می‌دهد، ساختار نامناسب سرمایه شرکت است. شرکت‌هایی که وابستگی زیادی به منابع مالی مبتنی بر بدهی دارند، در شرایط رکود اقتصادی یا افزایش نرخ بهره با ریسک بیشتری مواجه خواهند بود. افزایش اهرم مالی موجب افزایش هزینه‌های ثابت مالی شده و انعطاف‌پذیری شرکت را در مواجهه با شوک‌های اقتصادی کاهش می‌دهد. همچنین ضعف در مدیریت سرمایه در گردش، ناکارآمدی عملیاتی، تصمیمات سرمایه‌گذاری نامناسب و کاهش قدرت رقابتی نیز از جمله عوامل داخلی مؤثر بر درماندگی مالی به شمار می‌روند (بریگام و اوهارد، ۲۰۲۲).

علاوه بر عوامل داخلی، متغیرهای کلان اقتصادی نیز نقش مهمی در شکل‌گیری درماندگی مالی دارند. تورم، نرخ ارز، نرخ بهره، رشد اقتصادی، تحریم‌های اقتصادی و بی‌ثباتی‌های سیاسی از جمله عواملی هستند که می‌توانند عملکرد مالی شرکت‌ها را تحت تأثیر قرار دهند. در اقتصادهای در حال توسعه، از جمله ایران، تأثیر این متغیرها بر وضعیت مالی شرکت‌ها بسیار چشمگیر است. نوسانات شدید اقتصادی می‌تواند موجب افزایش

هزینه‌های تولید، کاهش قدرت خرید مصرف‌کنندگان و کاهش سودآوری شرکت‌ها شود که در نهایت احتمال ورود آن‌ها به وضعیت درماندگی مالی را افزایش می‌دهد (حسینی و همکاران، ۱۴۰۲).

از منظر سرمایه‌گذاران، پیش‌بینی درماندگی مالی اهمیت ویژه‌ای دارد؛ زیرا تصمیمات سرمایه‌گذاری تا حد زیادی بر مبنای ارزیابی ریسک و بازده صورت می‌گیرد. سرمایه‌گذاران همواره تلاش می‌کنند شرکت‌هایی را انتخاب کنند که از ثبات مالی و چشم‌انداز مطلوبی برخوردار باشند. در نتیجه، دسترسی به ابزارهایی که بتوانند احتمال درماندگی مالی را با دقت بالا پیش‌بینی کنند، موجب بهبود کیفیت تصمیم‌گیری و کاهش ریسک سرمایه‌گذاری خواهد شد. همچنین اعتباردهندگان و بانک‌ها نیز از نتایج مدل‌های پیش‌بینی درماندگی مالی برای ارزیابی ریسک اعتباری مشتریان و تعیین شرایط اعطای تسهیلات استفاده می‌کنند (باربوپولوس و لازاریس، ۲۰۲۳).

در مجموع، درماندگی مالی پدیده‌ای چندبعدی و پیچیده است که تحت تأثیر عوامل مالی، عملیاتی، مدیریتی و محیطی قرار دارد. اهمیت روزافزون این موضوع در بازارهای مالی موجب شده است که توسعه مدل‌های دقیق و هوشمند برای شناسایی و پیش‌بینی آن به یکی از اولویت‌های اصلی پژوهشگران و فعالان حوزه مالی تبدیل شود. شناسایی به‌موقع شرکت‌های در معرض درماندگی مالی نه تنها از بروز خسارات سنگین اقتصادی جلوگیری می‌کند، بلکه امکان اتخاذ اقدامات اصلاحی و بازسازی مالی را نیز فراهم می‌سازد. از این‌رو، درماندگی مالی همچنان یکی از مهم‌ترین موضوعات مورد مطالعه در ادبیات مالی و حسابداری معاصر به شمار می‌رود و نقش اساسی در مدیریت ریسک، تصمیم‌گیری سرمایه‌گذاران و ارتقای کارایی بازارهای سرمایه ایفا می‌کند.

۲-۲ ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یکی از قدرتمندترین و پرکاربردترین الگوریتم‌های یادگیری ماشین در حوزه طبقه‌بندی و رگرسیون محسوب می‌شود که طی سه دهه گذشته توجه گسترده‌ای را در میان پژوهشگران علوم کامپیوتر، آمار، مهندسی و علوم مالی به خود جلب کرده است. این الگوریتم نخستین بار توسط ولادیمیر واپنیک و همکارانش در دهه ۱۹۹۰ معرفی شد و بر پایه نظریه یادگیری آماری توسعه یافت (واپنیک، ۱۹۹۵). هدف اصلی ماشین بردار پشتیبان، یافتن یک مرز تصمیم‌گیری یا ابرصفحه بهینه برای جداسازی داده‌های متعلق به کلاس‌های مختلف است؛ به گونه‌ای که فاصله این ابرصفحه از نزدیک‌ترین نمونه‌های هر کلاس، که بردارهای پشتیبان نامیده می‌شوند، حداکثر شود. این ویژگی باعث می‌شود که مدل از توان تعمیم‌پذیری بالایی برخوردار باشد و بتواند در مواجهه با داده‌های جدید نیز عملکرد مناسبی ارائه دهد.

ظهور ماشین بردار پشتیبان را می‌توان نقطه عطفی در توسعه روش‌های یادگیری ماشین دانست؛ زیرا این الگوریتم توانست بسیاری از محدودیت‌های مدل‌های سنتی طبقه‌بندی را برطرف کند. پیش از توسعه SVM، بسیاری از روش‌های طبقه‌بندی مبتنی بر فرض آماری خاصی بودند و در مواجهه با داده‌های پیچیده و غیرخطی عملکرد مطلوبی نداشتند. در مقابل، ماشین بردار پشتیبان با بهره‌گیری از اصول بهینه‌سازی ریاضی و نظریه یادگیری آماری، چارچوبی قدرتمند برای طبقه‌بندی داده‌ها ارائه کرد که از نظر دقت و قابلیت تعمیم در بسیاری از مسائل از روش‌های سنتی پیشی گرفت (کورتس و واپنیک، ۱۹۹۵).

اساس عملکرد ماشین بردار پشتیبان بر مفهوم حاشیه استوار است. در مسائل طبقه‌بندی دودویی، هدف الگوریتم یافتن ابرصفحه‌ای است که بتواند داده‌های دو کلاس مختلف را از یکدیگر جدا کند. در میان بی‌نهایت ابرصفحه ممکن، SVM ابرصفحه‌ای را انتخاب می‌کند که بیشترین فاصله را از نزدیک‌ترین نمونه‌های آموزشی داشته باشد. این فاصله که حاشیه نامیده می‌شود، نقش مهمی در کاهش خطای تعمیم و افزایش دقت مدل دارد. هرچه مقدار حاشیه بیشتر باشد، احتمال بیش‌برازش کاهش یافته و مدل عملکرد پایدارتری در داده‌های جدید خواهد داشت (بیشاپ، ۲۰۰۶).

یکی از مهم‌ترین مزایای ماشین بردار پشتیبان، توانایی آن در مدل‌سازی روابط غیرخطی است. در بسیاری از مسائل واقعی، از جمله مسائل مالی، روابط میان متغیرها به صورت خطی نیست و نمی‌توان با استفاده از یک مرز تصمیم‌گیری ساده آن‌ها را از یکدیگر تفکیک کرد. برای حل این مسئله، SVM از مفهوم توابع هسته بهره می‌گیرد. توابع هسته داده‌ها را از فضای اولیه به فضایی با ابعاد بالاتر منتقل می‌کنند تا امکان جداسازی بهتر کلاس‌ها فراهم شود. این ویژگی موجب شده است که ماشین بردار پشتیبان بتواند روابط پیچیده و غیرخطی موجود در داده‌ها را با دقت بالایی مدل‌سازی کند (شولتکف و اسمولا، ۲۰۰۲).

توابع هسته‌ای مختلفی برای ماشین بردار پشتیبان توسعه یافته‌اند که هر یک برای شرایط خاصی مناسب هستند. هسته خطی، هسته چندجمله‌ای، هسته شعاعی یا تابع پایه شعاعی (RBF) و هسته سیگموئید از جمله رایج‌ترین توابع هسته محسوب می‌شوند. در میان این توابع، هسته RBF به دلیل انعطاف‌پذیری بالا و توانایی مناسب در مدل‌سازی روابط غیرخطی، بیشترین کاربرد را در مطالعات مالی و اقتصادی دارد (گراس و همکاران،

(۲۰۲۱). انتخاب نوع هسته و پارامترهای مرتبط با آن تأثیر مستقیمی بر عملکرد مدل دارد و یکی از مهم‌ترین مراحل طراحی سیستم‌های مبتنی بر SVM محسوب می‌شود.

از دیگر ویژگی‌های مهم ماشین بردار پشتیبان، مقاومت بالای آن در برابر بیش‌برازش است. بیش‌برازش زمانی رخ می‌دهد که مدل به جای یادگیری الگوهای کلی موجود در داده‌ها، جزئیات و نویزهای مجموعه آموزشی را فرا گیرد و در نتیجه عملکرد ضعیفی در داده‌های جدید داشته باشد. ساختار ریاضی SVM به گونه‌ای طراحی شده است که تعادلی مناسب میان پیچیدگی مدل و دقت طبقه‌بندی برقرار می‌کند. به همین دلیل، این الگوریتم حتی در شرایطی که حجم داده‌ها محدود باشد نیز قادر است عملکرد مطلوبی ارائه دهد (جیمز و همکاران، ۲۰۲۱).

یکی دیگر از مزایای برجسته ماشین بردار پشتیبان، کارایی آن در داده‌های با ابعاد بالا است. در بسیاری از کاربردهای مالی، تعداد متغیرهای ورودی بسیار زیاد است و الگوریتم‌های سنتی در مواجهه با چنین داده‌هایی با مشکلاتی نظیر افزایش پیچیدگی محاسباتی و کاهش دقت مواجه می‌شوند. در مقابل، SVM قادر است با حفظ دقت طبقه‌بندی، داده‌های چندبعدی را به خوبی مدیریت کند. این ویژگی باعث شده است که این الگوریتم در حوزه‌هایی نظیر تحلیل بازارهای مالی، ارزیابی ریسک اعتباری، پیش‌بینی ورشکستگی و تشخیص تقلب مالی کاربرد گسترده‌ای پیدا کند (هان، کامبر و پی، ۲۰۲۲).

در سال‌های اخیر، استفاده از ماشین بردار پشتیبان در علوم مالی رشد چشمگیری داشته است. بازارهای مالی محیط‌هایی پیچیده، پویا و سرشار از عدم قطعیت هستند که در آن‌ها روابط میان متغیرها غالباً غیرخطی و متأثر از عوامل متعدد اقتصادی، سیاسی و رفتاری است. الگوریتم SVM به دلیل توانایی بالای خود در استخراج الگوهای پنهان از داده‌های مالی، به ابزاری ارزشمند برای تحلیلگران مالی و پژوهشگران تبدیل شده است. مطالعات مختلف نشان داده‌اند که این الگوریتم در پیش‌بینی قیمت سهام، رتبه‌بندی اعتباری، مدیریت ریسک و شناسایی درماندگی مالی عملکرد موفقی داشته است (چن و همکاران، ۲۰۲۳).

یکی از مهم‌ترین کاربردهای ماشین بردار پشتیبان در حوزه مالی، پیش‌بینی درماندگی مالی و ورشکستگی شرکت‌ها است. پیش‌بینی وضعیت مالی شرکت‌ها به دلیل پیچیدگی روابط میان متغیرهای مالی و تأثیرپذیری از عوامل محیطی، همواره یکی از چالش‌های مهم پژوهشگران بوده است. مطالعات متعدد نشان داده‌اند که SVM قادر است با دقت بالاتری نسبت به بسیاری از روش‌های آماری سنتی، شرکت‌های سالم را از شرکت‌های در معرض درماندگی مالی تفکیک کند (سونگ و ژائو، ۲۰۲۲). این موضوع به ویژه برای سرمایه‌گذاران، بانک‌ها و نهادهای نظارتی اهمیت فراوانی دارد؛ زیرا شناسایی زود هنگام شرکت‌های در معرض بحران می‌تواند به کاهش ریسک سرمایه‌گذاری و بهبود تصمیم‌گیری‌های مالی کمک کند.

با وجود مزایای فراوان، عملکرد ماشین بردار پشتیبان به شدت تحت تأثیر انتخاب پارامترهای تنظیمی آن قرار دارد. مهم‌ترین این پارامترها شامل ضریب جریمه (C) و پارامتر هسته (γ) هستند. پارامتر C میزان جریمه خطاهای طبقه‌بندی را تعیین می‌کند و پارامتر γ نیز بر نحوه تأثیرگذاری نمونه‌های آموزشی در فضای ویژگی اثر می‌گذارد. انتخاب نامناسب این پارامترها می‌تواند منجر به کاهش دقت مدل و افزایش خطای پیش‌بینی شود. به همین دلیل، یکی از مهم‌ترین چالش‌های مرتبط با استفاده از SVM، تعیین مقادیر بهینه این پارامترها است (لیو و همکاران، ۲۰۲۴).

برای رفع این چالش، پژوهشگران در سال‌های اخیر از روش‌های مختلف بهینه‌سازی استفاده کرده‌اند. در این میان، الگوریتم‌های فراابتکاری نظیر الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات، الگوریتم کلونی مورچگان و الگوریتم گرگ خاکستری توانسته‌اند نتایج بسیار مطلوبی در تنظیم پارامترهای SVM ارائه دهند. این الگوریتم‌ها با جستجوی هوشمند در فضای پارامترها، مقادیر بهینه را شناسایی کرده و موجب بهبود دقت، سرعت و قابلیت تعمیم مدل می‌شوند (میرجلیلی، ۲۰۲۳). به همین دلیل، ترکیب ماشین بردار پشتیبان با الگوریتم‌های فراابتکاری به یکی از رویکردهای نوین و پرکاربرد در مطالعات پیش‌بینی درماندگی مالی تبدیل شده است.

در مجموع، ماشین بردار پشتیبان به دلیل برخورداری از ویژگی‌هایی نظیر دقت بالا، توانایی مدل‌سازی روابط غیرخطی، مقاومت در برابر بیش‌برازش، قابلیت پردازش داده‌های با ابعاد بالا و توانایی تعمیم مناسب، به یکی از مهم‌ترین ابزارهای تحلیل داده در حوزه مالی تبدیل شده است. شواهد پژوهشی نشان می‌دهد که این الگوریتم در پیش‌بینی درماندگی مالی شرکت‌ها عملکرد بسیار موفقی داشته و در صورت بهینه‌سازی مناسب پارامترها، می‌تواند به عنوان ابزاری قدرتمند برای شناسایی زود هنگام شرکت‌های در معرض بحران مالی مورد استفاده قرار گیرد.

۲-۳ الگوریتم‌های فراابتکاری

با گسترش روزافزون مسائل پیچیده بهینه‌سازی در حوزه‌های مختلف علمی، مهندسی، مالی و مدیریتی، نیاز به روش‌هایی که بتوانند در زمان معقول به پاسخ‌های نزدیک به بهینه دست یابند، بیش از پیش احساس شده است. بسیاری از مسائل واقعی دارای فضای جستجوی بسیار گسترده، توابع هدف غیرخطی، محدودیت‌های متعدد و ساختارهای پیچیده‌ای هستند که حل آن‌ها با استفاده از روش‌های کلاسیک ریاضی و الگوریتم‌های قطعی دشوار یا حتی غیرممکن است. در چنین شرایطی، الگوریتم‌های فراابتکاری به عنوان یکی از مهم‌ترین دستاوردهای علم محاسبات هوشمند مطرح شده‌اند. این الگوریتم‌ها مجموعه‌ای از روش‌های جستجوی عمومی و انعطاف‌پذیر هستند که با الهام از فرآیندهای طبیعی، زیستی، تکاملی و اجتماعی طراحی شده‌اند و هدف اصلی آن‌ها یافتن راه‌حل‌های نزدیک به بهینه برای مسائل پیچیده بهینه‌سازی است (بلوم و راولی، ۲۰۰۳).

اصطلاح فراابتکاری نخستین بار برای توصیف روش‌هایی به کار رفت که فراتر از الگوریتم‌های ابتکاری سنتی عمل می‌کنند و از راهبردهای هوشمند برای هدایت فرآیند جستجو در فضای پاسخ بهره می‌گیرند. برخلاف روش‌های دقیق که به دنبال یافتن جواب کاملاً بهینه هستند و معمولاً با افزایش ابعاد مسئله با مشکلات محاسباتی مواجه می‌شوند، الگوریتم‌های فراابتکاری تلاش می‌کنند در زمان مناسب به پاسخ‌هایی با کیفیت بالا دست یابند. این ویژگی موجب شده است که این الگوریتم‌ها در مسائل پیچیده‌ای نظیر زمان‌بندی، طراحی مهندسی، مدیریت زنجیره تأمین، تحلیل داده‌های بزرگ، یادگیری ماشین و پیش‌بینی مالی کاربرد گسترده‌ای پیدا کنند (یانگ، ۲۰۲۰).

یکی از مهم‌ترین ویژگی‌های الگوریتم‌های فراابتکاری، توانایی ایجاد تعادل میان دو مفهوم اکتشاف و بهره‌برداری است. اکتشاف به جستجوی گسترده در فضای پاسخ برای یافتن نواحی امیدوارکننده اشاره دارد، در حالی که بهره‌برداری به تمرکز بر بهترین راه‌حل‌های موجود و بهبود تدریجی آن‌ها مربوط می‌شود. الگوریتم‌های فراابتکاری موفق معمولاً به گونه‌ای طراحی می‌شوند که بتوانند میان این دو فرآیند تعادل برقرار کنند و از گرفتار شدن در بهینه‌های محلی جلوگیری نمایند (میرجلیلی و لوئیس، ۲۰۱۶). این ویژگی به ویژه در مسائل یادگیری ماشین اهمیت زیادی دارد، زیرا پارامترهای مدل‌ها اغلب دارای فضای جستجوی پیچیده و چندبعدی هستند.

در دهه‌های اخیر، پژوهشگران الگوریتم‌های فراابتکاری متعددی را توسعه داده‌اند که هر یک از پدیده‌ای خاص در طبیعت الهام گرفته‌اند. در میان این الگوریتم‌ها، الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات، الگوریتم کلونی مورچگان و الگوریتم گرگ خاکستری از محبوب‌ترین و پرکاربردترین روش‌ها محسوب می‌شوند. این الگوریتم‌ها به دلیل توانایی بالا در حل مسائل پیچیده و بهینه‌سازی پارامترهای مدل‌های یادگیری ماشین، در مطالعات مالی و اقتصادی مورد توجه ویژه قرار گرفته‌اند.

الگوریتم ژنتیک یکی از نخستین و شناخته‌شده‌ترین الگوریتم‌های فراابتکاری است که توسط جان هالند ارائه شد. این الگوریتم بر پایه نظریه تکامل داروین و اصل بقای اصلح طراحی شده است (هالند، ۱۹۷۵). در الگوریتم ژنتیک، هر راه‌حل به صورت یک کروموزوم نمایش داده می‌شود و مجموعه‌ای از راه‌حل‌ها جمعیتی از افراد را تشکیل می‌دهند. فرآیند جستجو از طریق اعمال عملگرهای انتخاب، تقاطع و جهش انجام می‌شود. در مرحله انتخاب، افراد با کیفیت بالاتر شانس بیشتری برای مشارکت در تولید نسل بعدی دارند. عملگر تقاطع موجب ترکیب ویژگی‌های دو والد و ایجاد فرزندان جدید می‌شود و عملگر جهش نیز با ایجاد تغییرات تصادفی، تنوع جمعیت را حفظ می‌کند. این فرآیند به صورت تکراری ادامه می‌یابد تا بهترین راه‌حل ممکن شناسایی شود. مطالعات متعدد نشان داده‌اند که الگوریتم ژنتیک در بهینه‌سازی پارامترهای مدل‌های یادگیری ماشین، انتخاب ویژگی‌ها و حل مسائل مالی عملکرد بسیار مطلوبی دارد (دب، ۲۰۲۱).

یکی دیگر از الگوریتم‌های فراابتکاری پرکاربرد، الگوریتم بهینه‌سازی ازدحام ذرات است که توسط کندی و ابرهات معرفی شد. این الگوریتم از رفتار اجتماعی پرندگان در جستجوی غذا و همچنین حرکت دسته‌جمعی ماهی‌ها الهام گرفته است (کندی و ابرهات، ۱۹۹۵). در PSO هر پاسخ بالقوه به صورت یک ذره در فضای جستجو نمایش داده می‌شود. هر ذره دارای موقعیت و سرعت مشخصی است و حرکت آن تحت تأثیر دو عامل اصلی قرار دارد: بهترین تجربه شخصی ذره و بهترین تجربه کل جمعیت. این مکانیزم باعث می‌شود ذرات به تدریج به سمت نواحی امیدوارکننده فضای جستجو حرکت کنند. سادگی ساختار، سرعت همگرایی بالا و توانایی مناسب در یافتن پاسخ‌های نزدیک به بهینه از مهم‌ترین مزایای این الگوریتم به شمار می‌رود. به همین دلیل، PSO به یکی از رایج‌ترین روش‌ها برای تنظیم پارامترهای ماشین بردار پشتیبان، شبکه‌های عصبی و سایر مدل‌های یادگیری ماشین تبدیل شده است (شریواستاوا و همکاران، ۲۰۲۳).

الگوریتم کلونی مورچگان نیز یکی از روش‌های فراابتکاری مشهور است که توسط دوریگو معرفی شد. این الگوریتم از رفتار طبیعی مورچه‌ها در یافتن کوتاه‌ترین مسیر بین لانه و منبع غذا الهام گرفته است (دوریگو و استوتزل، ۲۰۰۴). مورچه‌ها هنگام حرکت از خود ماده‌ای شیمیایی به نام

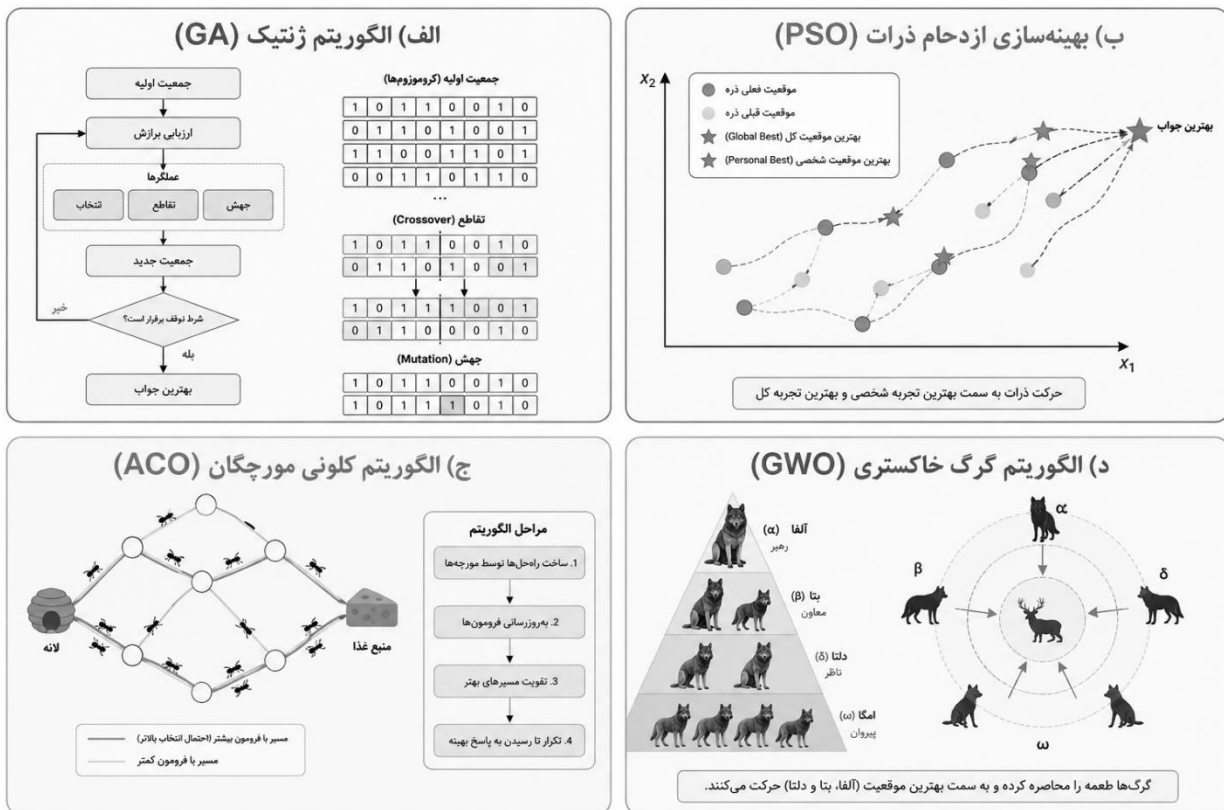
فرومون بر جای می‌گذارند. هرچه یک مسیر بیشتر مورد استفاده قرار گیرد، میزان فرومون موجود در آن افزایش می‌یابد و احتمال انتخاب آن توسط سایر مورچه‌ها بیشتر می‌شود. این فرآیند موجب می‌شود که در نهایت کوتاه‌ترین و کارآمدترین مسیر شناسایی شود. الگوریتم کلونی مورچگان این رفتار طبیعی را به یک روش جستجوی هوشمند تبدیل کرده و از آن برای حل مسائل پیچیده بهینه‌سازی استفاده می‌کند. این الگوریتم در مسائل مسیریابی، زمان‌بندی، انتخاب ویژگی و بهینه‌سازی پارامترهای مدل‌های یادگیری ماشین کاربرد گسترده‌ای دارد (ژائو و همکاران، ۲۰۲۲).

در سال‌های اخیر، الگوریتم گرگ خاکستری به عنوان یکی از موفق‌ترین الگوریتم‌های فراابتکاری مطرح شده است. این الگوریتم توسط میرجلیلی در سال ۲۰۱۴ معرفی شد و از ساختار اجتماعی و رفتار شکار گرگ‌های خاکستری الهام گرفته است (میرجلیلی و همکاران، ۲۰۱۴). در طبیعت، گرگ‌های خاکستری دارای سلسله‌مراتب اجتماعی مشخصی هستند که شامل گرگ‌های آلفا، بتا، دلتا و امگا می‌شود. فرآیند شکار نیز شامل مراحل شناسایی طعمه، محاصره و حمله است. الگوریتم GWO این رفتارها را به یک مکانیزم جستجوی ریاضی تبدیل کرده و از آن برای یافتن پاسخ‌های بهینه استفاده می‌کند. یکی از مهم‌ترین مزایای این الگوریتم، توانایی ایجاد تعادل مناسب میان اکتشاف و بهره‌برداری است که موجب افزایش دقت و جلوگیری از همگرایی زود هنگام می‌شود. مطالعات اخیر نشان داده‌اند که الگوریتم گرگ خاکستری در بسیاری از مسائل بهینه‌سازی از جمله تنظیم پارامترهای ماشین بردار پشتیبان، عملکردی رقابتی و حتی برتر نسبت به برخی الگوریتم‌های شناخته‌شده ارائه کرده است (میرجلیلی، ۲۰۲۳).

کاربرد الگوریتم‌های فراابتکاری در حوزه یادگیری ماشین طی سال‌های اخیر رشد چشمگیری داشته است. بسیاری از مدل‌های یادگیری ماشین دارای پارامترهای متعددی هستند که انتخاب مقادیر مناسب آن‌ها تأثیر مستقیمی بر عملکرد مدل دارد. تعیین این پارامترها از طریق آزمون و خطا یا جستجوی دستی نه تنها زمان‌بر است، بلکه ممکن است به پاسخ‌های بهینه منجر نشود. الگوریتم‌های فراابتکاری با جستجوی هوشمند در فضای پارامترها، امکان یافتن بهترین ترکیب پارامترها را فراهم می‌کنند و از این طریق دقت پیش‌بینی مدل را بهبود می‌بخشند (یانگ و همکاران، ۲۰۲۴).

در حوزه مالی، ترکیب الگوریتم‌های فراابتکاری با مدل‌های یادگیری ماشین به یکی از رویکردهای نوین و پرکاربرد تبدیل شده است. پژوهش‌های متعدد نشان داده‌اند که استفاده از الگوریتم‌هایی نظیر GA، PSO، ACO و GWO در بهینه‌سازی پارامترهای ماشین بردار پشتیبان می‌تواند دقت پیش‌بینی درماندگی مالی، ورشکستگی، ریسک اعتباری و نوسانات بازار را به طور قابل توجهی افزایش دهد (لی و همکاران، ۲۰۲۳). این الگوریتم‌ها با جستجوی مؤثر در فضای پاسخ و اجتناب از بهینه‌های محلی، شرایطی را فراهم می‌کنند که مدل‌های یادگیری ماشین بتوانند عملکرد بهتری در داده‌های واقعی و پیچیده مالی داشته باشند.

به طور کلی، الگوریتم‌های فراابتکاری یکی از مهم‌ترین ابزارهای محاسبات هوشمند در عصر حاضر محسوب می‌شوند. توانایی آن‌ها در حل مسائل پیچیده، انعطاف‌پذیری بالا، قابلیت سازگاری با انواع مسائل و عملکرد موفق در بهینه‌سازی مدل‌های یادگیری ماشین، موجب شده است که این الگوریتم‌ها جایگاه ویژه‌ای در پژوهش‌های علمی و کاربردهای صنعتی پیدا کنند. در حوزه پیش‌بینی درماندگی مالی نیز استفاده از الگوریتم‌های فراابتکاری در کنار ماشین بردار پشتیبان می‌تواند به بهبود دقت پیش‌بینی، افزایش قابلیت تعمیم مدل و ارتقای کیفیت تصمیم‌گیری مالی منجر شود و از این منظر نقش مهمی در توسعه سامانه‌های هوشمند مالی ایفا نماید.



شکل ۱: الگوریتم‌های فرا ابتکاری

۳- روش تحقیق

این پژوهش از نوع کاربردی است و با هدف توسعه و ارزیابی یک مدل هوشمند برای پیش‌بینی درماندگی مالی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران انجام می‌شود. رویکرد کلی مطالعه مبتنی بر داده‌های تاریخی و تحلیل کمی است و تلاش دارد با استفاده از تکنیک‌های یادگیری ماشین، الگوهای پنهان موجود در داده‌های مالی شرکت‌ها را شناسایی کرده و بر اساس آن، وضعیت مالی شرکت‌ها را به دو طبقه «سالم» و «درمانده مالی» طبقه‌بندی کند. در این راستا، از ماشین بردار پشتیبان (SVM) به‌عنوان مدل اصلی طبقه‌بندی استفاده می‌شود و به منظور افزایش دقت و کارایی آن، پارامترهای مدل از طریق الگوریتم‌های فراابتکاری بهینه‌سازی خواهند شد. بنابراین، این پژوهش از نظر هدف در دسته تحقیقات کاربردی و از نظر روش در زمره تحقیقات کمی و داده‌محور قرار می‌گیرد.

۳-۱ جامعه آماری

جامعه آماری این تحقیق شامل تمامی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران در بازه زمانی مورد بررسی است. انتخاب این جامعه به دلیل اهمیت بالای بازار سرمایه ایران و نقش کلیدی شرکت‌های بورسی در اقتصاد کشور انجام شده است. شرکت‌های پذیرفته‌شده در بورس معمولاً دارای اطلاعات مالی شفاف‌تر و قابل دسترس‌تری هستند که امکان انجام تحلیل‌های دقیق آماری و الگوریتمی را فراهم می‌سازد. علاوه بر این، تنوع صنایع و فعالیت‌های اقتصادی در بورس تهران موجب می‌شود که داده‌های مورد استفاده از نظر ساختاری دارای پراکندگی مناسبی بوده و مدل پیشنهادی بتواند قابلیت تعمیم‌پذیری بالاتری داشته باشد.

برای انتخاب نمونه آماری، شرکت‌هایی که دارای اطلاعات ناقص یا غیرقابل دسترس در صورت‌های مالی سالانه بوده‌اند از نمونه حذف خواهند شد. همچنین شرکت‌های فعال در صنایع مالی مانند بانک‌ها و مؤسسات اعتباری به دلیل تفاوت در ساختار صورت‌های مالی، در بسیاری از مطالعات مشابه از نمونه حذف می‌شوند تا همگنی داده‌ها افزایش یابد. در نهایت، نمونه نهایی شامل شرکت‌هایی خواهد بود که در طول دوره زمانی مورد مطالعه، اطلاعات مالی کامل و قابل اتکایی ارائه کرده‌اند.

۳-۲ متغیرهای پژوهش

در این پژوهش، متغیرها به دو دسته اصلی شامل متغیرهای مستقل و متغیر وابسته تقسیم می‌شوند. متغیرهای مستقل بر اساس نسبت‌های مالی انتخاب شده‌اند که به‌عنوان شاخص‌های کلیدی سلامت مالی شرکت‌ها در ادبیات مالی شناخته می‌شوند. این نسبت‌ها قادرند ابعاد مختلف عملکرد مالی از جمله نقدینگی، اهرم مالی، سودآوری و کارایی عملیاتی را پوشش دهند.

جدول ۱: متغیرهای مستقل پژوهش (نسبت‌های مالی منتخب)

ردیف	نام متغیر	توضیح
1	نسبت جاری	سنجش توانایی شرکت در پرداخت بدهی‌های کوتاه‌مدت
2	نسبت بدهی	میزان وابستگی شرکت به منابع مالی بدهی
3	بازده دارایی‌ها	سنجش کارایی استفاده از دارایی‌ها در ایجاد سود
4	بازده حقوق صاحبان سهام	میزان سودآوری برای سهامداران
5	حاشیه سود خالص	درصد سود خالص از فروش
6	گردش دارایی‌ها	کارایی استفاده از دارایی‌ها در تولید درآمد
7	جریان نقد عملیاتی	توانایی شرکت در ایجاد نقدینگی از فعالیت‌های عملیاتی

هر یک از این متغیرها نقش مهمی در تبیین وضعیت مالی شرکت دارند. به‌عنوان مثال، نسبت جاری به‌عنوان یکی از شاخص‌های مهم نقدینگی، نشان می‌دهد که آیا شرکت توانایی پوشش تعهدات کوتاه‌مدت خود را دارد یا خیر. نسبت بدهی نیز میزان اتکای شرکت به منابع مالی خارجی را مشخص می‌کند که افزایش بیش از حد آن می‌تواند نشانه‌ای از افزایش ریسک مالی باشد. از سوی دیگر، شاخص‌های سودآوری مانند ROA و ROE بیانگر توانایی شرکت در ایجاد بازده از منابع در اختیار هستند و کاهش آن‌ها معمولاً به‌عنوان یکی از نشانه‌های اولیه درماندگی مالی در نظر گرفته می‌شود.

حاشیه سود خالص و گردش دارایی‌ها نیز به ترتیب عملکرد شرکت در کنترل هزینه‌ها و استفاده بهینه از دارایی‌ها را نشان می‌دهند. در نهایت، جریان نقد عملیاتی یکی از مهم‌ترین شاخص‌ها در پیش‌بینی درماندگی مالی محسوب می‌شود، زیرا حتی شرکت‌هایی که از نظر حسابداری سودآور هستند ممکن است با کمبود نقدینگی مواجه شوند و در انجام تعهدات مالی خود ناتوان باشند. بنابراین، ترکیب این متغیرها می‌تواند تصویری جامع از وضعیت مالی شرکت ارائه دهد.

متغیر وابسته در این پژوهش وضعیت مالی شرکت است که به‌صورت یک متغیر طبقه‌بندی دودویی تعریف می‌شود. این متغیر شامل دو حالت «درمانده مالی» و «سالم» است. شرکت‌هایی که نشانه‌های مشخصی از ناتوانی در ایفای تعهدات مالی، زیان‌های مستمر، یا کاهش شدید نقدینگی دارند، در طبقه درمانده مالی قرار می‌گیرند. در مقابل، شرکت‌هایی که از ثبات مالی نسبی برخوردار بوده و توانایی ادامه فعالیت عادی را دارند، در طبقه سالم دسته‌بندی می‌شوند.

در این پژوهش، داده‌های مربوط به متغیرهای مستقل از صورت‌های مالی سالانه شرکت‌ها استخراج شده و پس از پردازش اولیه، به‌عنوان ورودی مدل SVM مورد استفاده قرار می‌گیرند. پیش از ورود داده‌ها به مدل، فرآیندهایی مانند نرمال‌سازی، حذف داده‌های پرت و یکسان‌سازی مقیاس متغیرها انجام خواهد شد تا از بروز خطاهای ناشی از اختلاف مقیاس داده‌ها جلوگیری شود.

همچنین به منظور افزایش دقت مدل، داده‌ها به دو بخش آموزش و آزمون تقسیم می‌شوند. بخش آموزش برای یادگیری الگوهای داده توسط مدل SVM استفاده شده و بخش آزمون برای ارزیابی عملکرد مدل در پیش‌بینی داده‌های جدید به کار می‌رود. این تقسیم‌بندی امکان بررسی قابلیت تعمیم‌پذیری مدل را فراهم می‌کند و از بروز بیش‌برازش جلوگیری خواهد کرد.

در نهایت، ساختار کلی پژوهش به گونه‌ای طراحی شده است که بتواند با ترکیب داده‌های مالی، الگوریتم ماشین بردار پشتیبان و روش‌های بهینه‌سازی فراابتکاری، یک چارچوب جامع برای پیش‌بینی درماندگی مالی ارائه دهد. انتظار می‌رود که استفاده از این رویکرد ترکیبی بتواند دقت پیش‌بینی را نسبت به روش‌های سنتی به‌طور قابل توجهی افزایش دهد و ابزار مناسبی برای تحلیل‌گران مالی، سرمایه‌گذاران و نهادهای نظارتی فراهم آورد.

۳-۳ مراحل اجرای مدل

اجرای مدل پیشنهادی در این پژوهش به صورت یک فرآیند نظام مند و چندمرحله‌ای طراحی شده است تا بتواند با حداقل خطا و بیشترین دقت، وضعیت مالی شرکت‌ها را پیش‌بینی کند. این مراحل به گونه‌ای تدوین شده‌اند که از مرحله جمع‌آوری داده‌ها تا ارزیابی نهایی عملکرد مدل را پوشش دهند و امکان بازتولید نتایج در مطالعات آتی را فراهم سازند.

در نخستین گام، جمع‌آوری داده‌های مالی شرکت‌ها انجام می‌شود. در این مرحله، اطلاعات مربوط به صورت‌های مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران از منابع معتبر مانند گزارش‌های سالانه، صورت‌های سود و زیان، ترازنامه‌ها و صورت جریان وجوه نقد استخراج می‌شود. این داده‌ها پایه اصلی تحلیل را تشکیل می‌دهند و کیفیت آن‌ها نقش تعیین‌کننده‌ای در دقت مدل نهایی دارد. به همین دلیل، تلاش می‌شود داده‌ها از منابع رسمی و قابل اعتماد گردآوری شوند تا از بروز خطاهای اطلاعاتی جلوگیری شود.

در مرحله دوم، پیش‌پردازش و نرمال‌سازی داده‌ها انجام می‌گیرد. داده‌های مالی معمولاً دارای مقیاس‌های متفاوت و ناهمگون هستند؛ به عنوان مثال، برخی متغیرها به صورت درصدی و برخی دیگر به صورت ریالی یا نسبی بیان می‌شوند. این تفاوت مقیاس می‌تواند عملکرد الگوریتم‌های یادگیری ماشین را تحت تأثیر قرار دهد. بنابراین، در این مرحله داده‌ها پاک‌سازی شده، مقادیر گم‌شده مدیریت می‌شوند و در نهایت با استفاده از روش‌های استاندارد نرمال‌سازی مانند Min-Max یا Z-Score به یک مقیاس واحد تبدیل می‌شوند.

در گام سوم، داده‌ها به مجموعه آموزش و آزمون تقسیم می‌شوند. این تقسیم‌بندی به منظور ارزیابی توان تعمیم‌پذیری مدل انجام می‌شود. معمولاً بخش عمده‌ای از داده‌ها (مانند ۷۰ تا ۸۰ درصد) برای آموزش مدل و بخش باقی‌مانده برای آزمون و ارزیابی عملکرد نهایی مورد استفاده قرار می‌گیرد. این رویکرد کمک می‌کند تا مشخص شود مدل تا چه حد قادر است الگوهای یادگرفته شده را بر روی داده‌های جدید و مشاهده نشده به درستی اعمال کند.

در مرحله چهارم، طراحی مدل پایه ماشین بردار پشتیبان صورت می‌گیرد. در این مرحله، الگوریتم SVM به عنوان مدل اصلی طبقه‌بندی پیاده‌سازی شده و ساختار اولیه آن بر اساس داده‌های آموزشی شکل می‌گیرد. انتخاب نوع هسته (Kernel) در این مرحله اهمیت زیادی دارد و معمولاً از هسته RBF به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی استفاده می‌شود.

در گام پنجم، بهینه‌سازی پارامترهای C و γ با استفاده از الگوریتم‌های فراابتکاری انجام می‌شود. پارامتر C میزان جریمه خطاهای طبقه‌بندی را تعیین می‌کند و پارامتر γ نیز بر گستره تأثیر نمونه‌ها در فضای ویژگی اثرگذار است. انتخاب نامناسب این پارامترها می‌تواند منجر به کاهش دقت مدل یا بیش‌برازش شود. در این پژوهش، الگوریتم‌هایی مانند الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات یا الگوریتم کلونی مورچگان برای یافتن مقادیر بهینه این پارامترها به کار گرفته می‌شوند.

در مرحله ششم، آموزش مدل ترکیبی SVM بهینه‌شده انجام می‌شود. در این بخش، مقادیر بهینه به دست آمده از الگوریتم‌های فراابتکاری به مدل SVM اعمال شده و مدل نهایی بر اساس داده‌های آموزشی آموزش داده می‌شود. این ترکیب موجب افزایش دقت، پایداری و توان تعمیم‌پذیری مدل در پیش‌بینی وضعیت مالی شرکت‌ها خواهد شد.

در نهایت، در مرحله هفتم، ارزیابی عملکرد مدل صورت می‌گیرد. در این مرحله، مدل آموزش دیده بر روی داده‌های آزمون اجرا شده و عملکرد آن با استفاده از شاخص‌های مختلف ارزیابی می‌شود. این ارزیابی نشان می‌دهد که مدل تا چه اندازه در طبقه‌بندی صحیح شرکت‌های سالم و درمانده مالی موفق بوده است.

۳-۴ معیارهای ارزیابی عملکرد

برای ارزیابی دقت و کارایی مدل پیشنهادی، از مجموعه‌ای از معیارهای استاندارد در مسائل طبقه‌بندی استفاده می‌شود. این معیارها امکان سنجش عملکرد مدل را از جنبه‌های مختلف فراهم کرده و تصویر جامعی از توانایی پیش‌بینی آن ارائه می‌دهند.

دقت

دقت یکی از مهم‌ترین معیارهای ارزیابی در مسائل طبقه‌بندی است که نشان می‌دهد چه نسبتی از پیش‌بینی‌های مدل به درستی انجام شده است. به عبارت دیگر، دقت نسبت تعداد پیش‌بینی‌های صحیح (چه مثبت و چه منفی) به کل نمونه‌ها را نشان می‌دهد. هرچه مقدار این شاخص بالاتر باشد، عملکرد کلی مدل بهتر ارزیابی می‌شود.

حساسیت: حساسیت که با نام نرخ شناسایی صحیح مثبت‌ها نیز شناخته می‌شود، توانایی مدل در شناسایی صحیح شرکت‌های درمانده مالی را اندازه‌گیری می‌کند. در واقع این معیار نشان می‌دهد مدل تا چه اندازه قادر است موارد واقعی درماندگی مالی را به‌درستی تشخیص دهد. در مسائل مالی، حساسیت بالا از اهمیت ویژه‌ای برخوردار است، زیرا عدم شناسایی شرکت‌های در معرض بحران می‌تواند پیامدهای جدی به همراه داشته باشد.

ویژگی: ویژگی یا نرخ شناسایی صحیح منفی‌ها، توانایی مدل در تشخیص شرکت‌های سالم را نشان می‌دهد. این معیار بیان می‌کند که مدل تا چه حد قادر است شرکت‌هایی را که از نظر مالی سالم هستند به‌درستی شناسایی کند و از طبقه‌بندی اشتباه آن‌ها به‌عنوان شرکت درمانده جلوگیری نماید.

امتیاز F1: امتیاز F1 یکی از معیارهای ترکیبی است که به‌صورت میانگین هارمونیک دقت و حساسیت محاسبه می‌شود. این شاخص زمانی اهمیت بیشتری پیدا می‌کند که داده‌ها نامتوازن باشند، یعنی تعداد شرکت‌های سالم و درمانده برابر نباشد. F1 تلاش می‌کند تعادلی میان شناسایی صحیح مثبت‌ها و کاهش خطای مثبت کاذب برقرار کند.

سطح زیر منحنی (AUC) ROC: معیار AUC یکی از مهم‌ترین شاخص‌های ارزیابی در مدل‌های طبقه‌بندی است که عملکرد کلی مدل را در تمام آستانه‌های تصمیم‌گیری نشان می‌دهد. منحنی ROC رابطه بین حساسیت و نرخ خطای مثبت کاذب را نمایش می‌دهد و مقدار AUC بیانگر قدرت تفکیک مدل بین دو کلاس است. هرچه مقدار AUC به ۱ نزدیک‌تر باشد، مدل دارای قدرت تفکیک بالاتری خواهد بود.

۴-نتایج

با توجه به چارچوب نظری و روش‌شناسی ارائه‌شده در این پژوهش، انتظار می‌رود استفاده از مدل‌های ترکیبی مبتنی بر ماشین بردار پشتیبان و الگوریتم‌های فراابتکاری، نسبت به مدل پایه SVM بهبود قابل توجهی در عملکرد پیش‌بینی درماندگی مالی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران ایجاد کند. این بهبود نه‌تنها در سطح افزایش دقت کلی مدل قابل مشاهده خواهد بود، بلکه در ابعاد مختلفی همچون کاهش خطاهای طبقه‌بندی، افزایش توان تشخیص شرکت‌های در معرض بحران، و ارتقای قابلیت تعمیم‌پذیری مدل نیز نمود پیدا خواهد کرد. در واقع، هدف اصلی از ترکیب الگوریتم‌های هوشمند بهینه‌سازی با SVM، غلبه بر محدودیت‌های ذاتی مدل‌های کلاسیک در انتخاب پارامترهای بهینه و بهبود عملکرد در شرایط پیچیده و غیرخطی داده‌های مالی است.

در گام نخست، انتظار می‌رود مهم‌ترین دستاورد این رویکرد، افزایش دقت پیش‌بینی باشد. در مسائل مالی، به‌ویژه پیش‌بینی درماندگی مالی، دقت مدل نقش تعیین‌کننده‌ای در اعتبار نتایج دارد، زیرا حتی درصد کمی از خطا می‌تواند منجر به تصمیمات نادرست سرمایه‌گذاری یا اعتباردهی شود. مدل پایه SVM اگرچه در مقایسه با بسیاری از روش‌های سنتی عملکرد مناسبی دارد، اما حساسیت بالای آن نسبت به انتخاب پارامترهای کلیدی مانند C و γ باعث می‌شود در برخی شرایط بهینه نباشد. در این پژوهش، انتظار می‌رود استفاده از الگوریتم‌های فراابتکاری مانند الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و الگوریتم گرگ خاکستری موجب شود این پارامترها به صورت خودکار و بهینه تنظیم شده و در نتیجه مرز تصمیم‌گیری مدل به شکل دقیق‌تری در فضای ویژگی‌ها شکل گیرد. این فرآیند به طور مستقیم موجب افزایش دقت طبقه‌بندی شرکت‌ها به دو گروه سالم و درمانده خواهد شد. در کنار افزایش دقت، یکی دیگر از نتایج مهم مورد انتظار، کاهش خطاهای طبقه‌بندی است. در مدل‌های پیش‌بینی مالی، خطاها معمولاً به دو دسته خطای نوع اول و خطای نوع دوم تقسیم می‌شوند. خطای نوع اول زمانی رخ می‌دهد که یک شرکت سالم به اشتباه به عنوان درمانده مالی شناسایی شود، در حالی که خطای نوع دوم زمانی اتفاق می‌افتد که یک شرکت واقعاً درمانده، به عنوان شرکت سالم طبقه‌بندی شود. از منظر اقتصادی و مدیریتی، خطای نوع دوم معمولاً پیامدهای به مراتب سنگین‌تری دارد، زیرا عدم شناسایی شرکت‌های در معرض بحران می‌تواند منجر به زیان‌های مالی گسترده برای سرمایه‌گذاران، بانک‌ها و سایر ذی‌نفعان شود. انتظار می‌رود مدل‌های ترکیبی با استفاده از الگوریتم‌های فراابتکاری بتوانند تعادل بهتری میان این دو نوع خطا برقرار کنند و نرخ خطای کلی مدل را کاهش دهند.

یکی دیگر از نتایج کلیدی مورد انتظار، افزایش توانایی مدل در شناسایی شرکت‌های درمانده مالی است. یکی از چالش‌های اساسی در داده‌های مالی، نامتوازن بودن داده‌ها است؛ به این معنا که تعداد شرکت‌های سالم معمولاً به مراتب بیشتر از شرکت‌های درمانده است. این عدم توازن می‌تواند موجب شود مدل‌های کلاسیک تمایل بیشتری به پیش‌بینی کلاس اکثریت داشته باشند و در نتیجه، عملکرد ضعیفی در شناسایی

شرکت‌های بحران‌زده از خود نشان دهند. در این پژوهش، انتظار می‌رود استفاده از الگوریتم‌های فراابتکاری باعث تنظیم بهینه مرز تصمیم‌گیری شود، به گونه‌ای که مدل حساسیت بیشتری نسبت به کلاس اقلیت (شرکت‌های درمانده) داشته باشد. این موضوع به‌ویژه برای نهادهای نظارتی و سرمایه‌گذاران اهمیت زیادی دارد، زیرا شناسایی به‌موقع شرکت‌های در معرض ورشکستگی می‌تواند از بروز خسارات جدی جلوگیری کند. در ادامه، یکی دیگر از نتایج مورد انتظار، افزایش ویژگی مدل است. این شاخص نشان می‌دهد که مدل تا چه اندازه قادر است شرکت‌های سالم را به‌درستی شناسایی کرده و از طبقه‌بندی اشتباه آن‌ها به عنوان شرکت درمانده جلوگیری کند. در بسیاری از مدل‌های پیش‌بینی، تمرکز بیش از حد بر شناسایی کلاس اقلیت ممکن است منجر به کاهش دقت در طبقه‌بندی کلاس اکثریت شود. با این حال، انتظار می‌رود استفاده از الگوریتم‌های فراابتکاری موجب ایجاد تعادل مناسب میان حساسیت و ویژگی شود، به گونه‌ای که مدل بتواند هر دو گروه را با دقت قابل قبول شناسایی کند. از دیگر نتایج مهم این پژوهش، بهبود امتیاز F1 خواهد بود. این شاخص به‌عنوان میانگین هارمونیک دقت و حساسیت در شرایطی که داده‌ها نامتوازن هستند، اهمیت ویژه‌ای پیدا می‌کند. با توجه به اینکه در مسائل مالی معمولاً تعداد نمونه‌های مربوط به شرکت‌های سالم بیشتر از شرکت‌های درمانده است، استفاده از F1 Score می‌تواند ارزیابی دقیق‌تری از عملکرد مدل ارائه دهد. انتظار می‌رود مدل‌های ترکیبی نسبت به مدل پایه SVM، امتیاز F1 بالاتری کسب کنند که نشان‌دهنده تعادل بهتر میان شناسایی صحیح شرکت‌های درمانده و کاهش خطاهای مثبت کاذب است.

همچنین، انتظار می‌رود سطح زیر منحنی ROC (AUC) در مدل‌های ترکیبی به طور قابل توجهی افزایش یابد. معیار AUC یکی از مهم‌ترین شاخص‌های ارزیابی در مسائل طبقه‌بندی است که توانایی کلی مدل در تفکیک دو کلاس را بدون وابستگی به یک آستانه خاص نشان می‌دهد. هرچه مقدار AUC به عدد ۱ نزدیک‌تر باشد، قدرت تفکیک مدل بیشتر خواهد بود. در این پژوهش، استفاده از الگوریتم‌های فراابتکاری برای بهینه‌سازی پارامترهای SVM می‌تواند موجب افزایش قدرت جداسازی مدل شده و در نتیجه مقدار AUC را بهبود بخشد.

در میان الگوریتم‌های مورد استفاده، انتظار می‌رود الگوریتم بهینه‌سازی ازدحام ذرات و الگوریتم گرگ خاکستری عملکرد بهتری نسبت به سایر روش‌ها داشته باشند. دلیل این انتظار، ساختار جستجوی کارآمد و توانایی بالای این الگوریتم‌ها در اکتشاف و بهره‌برداری همزمان از فضای پاسخ است. PSO با الهام از رفتار اجتماعی پرندگان و ماهی‌ها، به صورت تدریجی به سمت بهترین پاسخ حرکت می‌کند و معمولاً سرعت همگرایی بالایی دارد. در مقابل، GWO با بهره‌گیری از ساختار سلسله‌مراتبی گرگ‌ها و فرآیند شکار گروهی، توانایی بالایی در جلوگیری از گیر افتادن در بهینه‌های محلی دارد و می‌تواند تعادل مناسبی میان جستجوی گسترده و تمرکز بر نواحی بهینه ایجاد کند. این ویژگی‌ها موجب می‌شود این دو الگوریتم در مقایسه با سایر روش‌ها مانند الگوریتم ژنتیک، عملکرد بهینه‌تری در تنظیم پارامترهای SVM ارائه دهند.

در عین حال، الگوریتم ژنتیک (GA) نیز به دلیل ماهیت تکاملی خود و توانایی در تولید تنوع در جمعیت راه‌حل‌ها، انتظار می‌رود نتایج قابل قبولی ارائه دهد، هرچند ممکن است نسبت به PSO و GWO نیازمند تنظیم دقیق‌تر پارامترهای کنترلی باشد. با این حال، تمامی الگوریتم‌های فراابتکاری مورد استفاده در این پژوهش نسبت به مدل پایه SVM بدون بهینه‌سازی، عملکرد بهتری از خود نشان خواهند داد.

در سطحی کلان‌تر، نتایج مورد انتظار این پژوهش نشان می‌دهد که ترکیب یادگیری ماشین و الگوریتم‌های فراابتکاری می‌تواند یک چارچوب قدرتمند برای تحلیل داده‌های مالی پیچیده فراهم کند. این چارچوب نه تنها در حوزه پیش‌بینی درماندگی مالی، بلکه در سایر حوزه‌های مالی مانند پیش‌بینی ورشکستگی، ارزیابی ریسک اعتباری، تحلیل نوسانات بازار و مدیریت پرتفوی نیز قابل استفاده خواهد بود. یکی از مهم‌ترین مزایای این رویکرد، توانایی آن در استخراج الگوهای پنهان از داده‌های مالی و تصمیم‌گیری مبتنی بر داده‌های واقعی است که می‌تواند به بهبود کیفیت تصمیمات مالی در سطح شرکت‌ها و بازار سرمایه کمک کند.

در نهایت، انتظار می‌رود نتایج این پژوهش نشان دهد که استفاده از مدل‌های ترکیبی SVM-فراابتکاری نه تنها از نظر آماری برتر از مدل‌های کلاسیک است، بلکه از نظر عملی نیز قابلیت استفاده در سیستم‌های تصمیم‌یار مالی را دارد. این مدل‌ها می‌توانند به عنوان ابزارهای کمکی برای مدیران مالی، تحلیلگران، سرمایه‌گذاران و نهادهای نظارتی مورد استفاده قرار گیرند و نقش مهمی در ارتقای شفافیت، کاهش ریسک و بهبود کارایی بازار سرمایه ایفا کنند.

در این پژوهش تلاش شد با تکیه بر ادبیات نظری موجود در حوزه پیش‌بینی درماندگی مالی و بهره‌گیری از رویکردهای نوین یادگیری ماشین، چارچوبی ترکیبی مبتنی بر ماشین بردار پشتیبان و الگوریتم‌های فراابتکاری برای بهبود دقت پیش‌بینی وضعیت مالی شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران ارائه شود. همان‌طور که در مبانی نظری اشاره شد، پیش‌بینی درماندگی مالی یکی از مسائل کلاسیک و در عین حال

پیچیده در ادبیات مالی و حسابداری است که از دهه ۱۹۶۰ میلادی تاکنون مورد توجه پژوهشگران قرار گرفته است. از مدل‌های اولیه مبتنی بر نسبت‌های مالی و تحلیل ممیزی چندگانه آتمن گرفته تا مدل‌های رگرسیون لجستیک و سپس ورود روش‌های هوش مصنوعی و یادگیری ماشین، همواره هدف اصلی پژوهشگران افزایش دقت پیش‌بینی و کاهش خطا در شناسایی شرکت‌های در معرض ورشکستگی بوده است. در این مسیر، تحقیقات مختلف نشان داده‌اند که مدل‌های سنتی اگرچه از نظر تفسیرپذیری ساده‌تر هستند، اما در مواجهه با روابط غیرخطی و پیچیده موجود در داده‌های مالی عملکرد محدودی دارند. همین مسئله موجب شده است که رویکردهای مبتنی بر داده‌کاوی و الگوریتم‌های هوشمند به‌عنوان جایگزین یا مکمل روش‌های کلاسیک مطرح شوند.

در میان روش‌های نوین، ماشین بردار پشتیبان به دلیل ساختار مبتنی بر حاشیه بیشینه و توانایی بالا در تعمیم‌پذیری، جایگاه ویژه‌ای در مطالعات مالی پیدا کرده است. پژوهش‌های متعددی از جمله مطالعات مین و لی (۲۰۰۵)، هان و همکاران (۲۰۲۲) و چن و همکاران (۲۰۲۳) نشان داده‌اند که SVM در بسیاری از مسائل طبقه‌بندی مالی از جمله پیش‌بینی ورشکستگی، ارزیابی ریسک اعتباری و تشخیص درماندگی مالی عملکردی بهتر از مدل‌های آماری کلاسیک مانند رگرسیون لجستیک و تحلیل ممیزی چندگانه دارد. با این حال، یکی از چالش‌های اساسی در استفاده از این الگوریتم، حساسیت بالای آن نسبت به انتخاب پارامترهای تنظیمی است. پارامترهایی مانند C و γ نقش تعیین‌کننده‌ای در شکل‌گیری مرز تصمیم‌گیری دارند و انتخاب نادرست آن‌ها می‌تواند منجر به بیش‌برازش یا کم‌برازش مدل شود. همین مسئله در تحقیقات اخیر نیز به‌عنوان یکی از نقاط ضعف SVM مطرح شده و پژوهشگران را به سمت استفاده از روش‌های بهینه‌سازی سوق داده است.

در این راستا، الگوریتم‌های فراابتکاری به‌عنوان ابزارهای قدرتمند جستجوی جهانی مورد توجه قرار گرفته‌اند. الگوریتم‌هایی مانند ژنتیک، بهینه‌سازی ازدحام ذرات و گرگ خاکستری در مطالعات مختلف نشان داده‌اند که می‌توانند فضای پارامترهای مدل‌های یادگیری ماشین را به‌صورت کارآمد جستجو کرده و ترکیب بهینه‌ای از پارامترها را شناسایی کنند. به عنوان مثال، نتایج پژوهش‌های میرجلی و همکاران (۲۰۱۴) و (۲۰۲۳) نشان می‌دهد که الگوریتم گرگ خاکستری به دلیل ساختار سلسله‌مراتبی و مکانیزم متعادل اکتشاف و بهره‌برداری، در بسیاری از مسائل بهینه‌سازی نسبت به الگوریتم‌های کلاسیک عملکرد رقابتی یا حتی برتر دارد. همچنین، کندی و ابرهات (۱۹۹۵) در معرفی PSO نشان دادند که رفتار جمعی می‌تواند به همگرایی سریع و مؤثر در فضای جستجو منجر شود. از سوی دیگر، الگوریتم ژنتیک نیز با الهام از فرآیند تکامل طبیعی، قابلیت بالایی در حفظ تنوع پاسخ‌ها و جلوگیری از گیر افتادن در بهینه‌های محلی دارد. تطبیق این یافته‌ها با ادبیات پیش‌بینی مالی نشان می‌دهد که استفاده از این الگوریتم‌ها در کنار SVM می‌تواند به شکل معناداری عملکرد مدل‌های پیش‌بینی را بهبود دهد، موضوعی که در مطالعات لی و همکاران (۲۰۲۳) نیز مورد تأیید قرار گرفته است.

در این پژوهش نیز بر همین مبنا انتظار می‌رود که ترکیب SVM با الگوریتم‌های فراابتکاری نسبت به مدل پایه، عملکرد بهتری در پیش‌بینی درماندگی مالی ارائه دهد. با این حال، باید توجه داشت که نتایج به‌دست‌آمده در چنین مدل‌هایی همواره تحت تأثیر کیفیت داده‌ها، انتخاب متغیرها و شرایط اقتصادی قرار دارند. یکی از مهم‌ترین محدودیت‌های این پژوهش، محدود بودن داده‌ها به شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران است. اگرچه این داده‌ها از نظر شفافیت و دسترسی در سطح مناسبی قرار دارند، اما نمی‌توانند نماینده کامل تمامی بنگاه‌های اقتصادی کشور باشند. در نتیجه، تعمیم نتایج به سایر بازارها یا شرکت‌های خارج از بورس باید با احتیاط انجام شود.

محدودیت دیگر مربوط به دوره زمانی مورد بررسی است. شرایط اقتصادی ایران به دلیل نوسانات نرخ ارز، تورم، تحریم‌های بین‌المللی و تغییرات سیاست‌های کلان اقتصادی دارای بی‌ثباتی‌های قابل توجهی است. این موضوع ممکن است باعث شود که الگوهای یادگیری شده توسط مدل در برخی دوره‌ها قابل تعمیم به دوره‌های دیگر نباشند. به عبارت دیگر، ماهیت پویا و غیرایستای داده‌های مالی می‌تواند یکی از چالش‌های اصلی در عملکرد مدل‌های یادگیری ماشین باشد. همچنین، وابستگی مدل به کیفیت داده‌های مالی نیز از دیگر محدودیت‌های مهم این پژوهش است؛ به‌گونه‌ای که وجود خطا در گزارش‌های مالی یا عدم شفافیت اطلاعات می‌تواند دقت پیش‌بینی را تحت تأثیر قرار دهد.

از سوی دیگر، اگرچه استفاده از الگوریتم‌های فراابتکاری موجب بهبود عملکرد مدل می‌شود، اما این الگوریتم‌ها خود نیز دارای پیچیدگی محاسباتی و زمان اجرای نسبتاً بالایی هستند. به‌ویژه در مسائل با ابعاد بالا و داده‌های حجیم، فرآیند بهینه‌سازی ممکن است زمان‌بر باشد. علاوه بر این، انتخاب پارامترهای داخلی الگوریتم‌های فراابتکاری نیز می‌تواند بر نتایج نهایی تأثیرگذار باشد و در برخی موارد نیازمند تنظیم دقیق و آزمون و خطا است. این موضوع نشان می‌دهد که اگرچه این روش‌ها قدرتمند هستند، اما همچنان چالش‌هایی در زمینه بهینه‌سازی عملی آن‌ها وجود دارد.

در بخش دیگری از این پژوهش می‌توان به محدودیت‌های مرتبط با تفسیرپذیری مدل نیز اشاره کرد. مدل‌های مبتنی بر SVM به‌ویژه زمانی که با الگوریتم‌های فراابتکاری ترکیب می‌شوند، به سمت مدل‌های جعبه سیاه حرکت می‌کنند. این موضوع باعث می‌شود که درک دقیق روابط میان متغیرهای مالی و تأثیر هر یک از آن‌ها بر نتیجه نهایی دشوارتر شود. در حالی که در مدل‌های کلاسیک مانند رگرسیون لجستیک، تفسیر ضرایب به‌سادگی امکان‌پذیر است، در مدل‌های یادگیری ماشین این ویژگی تا حدی کاهش می‌یابد. بنابراین، یکی از چالش‌های مهم در استفاده عملی از این مدل‌ها، ایجاد تعادل میان دقت پیش‌بینی و قابلیت تفسیر نتایج است.

با وجود این محدودیت‌ها، نتایج و مبانی نظری پژوهش نشان می‌دهد که استفاده از مدل‌های ترکیبی SVM و الگوریتم‌های فراابتکاری می‌تواند مزایای قابل توجهی برای حوزه مالی به همراه داشته باشد. از منظر کاربردی، این مدل‌ها می‌توانند به‌عنوان ابزارهای تصمیم‌یار در اختیار مدیران مالی شرکت‌ها قرار گیرند تا بتوانند وضعیت سلامت مالی سازمان خود را به‌صورت دوره‌ای پیش‌بینی کنند و در صورت مشاهده نشانه‌های اولیه درماندگی مالی، اقدامات اصلاحی لازم را به‌موقع انجام دهند. همچنین سرمایه‌گذاران می‌توانند از این مدل‌ها برای ارزیابی ریسک سرمایه‌گذاری در شرکت‌های مختلف استفاده کنند و تصمیمات خود را بر مبنای تحلیل‌های داده‌محور اتخاذ نمایند.

از سوی دیگر، بانک‌ها و مؤسسات اعتباری نیز می‌توانند از این رویکرد برای بهبود سیستم‌های اعتبارسنجی خود بهره‌برند. استفاده از مدل‌های پیش‌بینی درماندگی مالی می‌تواند به این نهادها کمک کند تا ریسک نکول تسهیلات را کاهش دهند و سیاست‌های اعتباری دقیق‌تری تدوین کنند. در سطح کلان نیز نهادهای نظارتی و سازمان بورس می‌توانند از این مدل‌ها برای شناسایی شرکت‌های پرریسک و افزایش شفافیت بازار استفاده کنند. این موضوع در نهایت به بهبود کارایی بازار سرمایه و کاهش ریسک سیستماتیک منجر خواهد شد.

در مجموع، می‌توان نتیجه گرفت که ترکیب ماشین بردار پشتیبان با الگوریتم‌های فراابتکاری یک رویکرد مؤثر و قابل اتکا در پیش‌بینی درماندگی مالی است که هم از نظر نظری با ادبیات پیشین همخوانی دارد و هم از نظر عملی قابلیت کاربرد در سیستم‌های واقعی تصمیم‌گیری مالی را دارد. با این حال، برای بهبود نتایج در تحقیقات آینده پیشنهاد می‌شود از داده‌های گسترده‌تر، دوره‌های زمانی طولانی‌تر و همچنین ترکیب این مدل با سایر روش‌های یادگیری عمیق استفاده شود. همچنین بررسی نقش متغیرهای کلان اقتصادی در کنار نسبت‌های مالی می‌تواند دقت مدل را بیش از پیش افزایش دهد و تصویر جامع‌تری از وضعیت مالی شرکت‌ها ارائه دهد.

منابع

منابع فارسی

مقالات

- احمدی، م.، و کریمی، ن. (۱۴۰۱). کاربرد ماشین‌های بردار پشتیبان در پیش‌بینی ورشکستگی شرکت‌ها. فصلنامه پژوهش‌های مالی ایران، ۱۹ (۲)، ۴۵-۶۸.
- حسینی، ع.، و موسوی، س. (۱۴۰۰). تحلیل درماندگی مالی با استفاده از داده کاوی. نشریه مدیریت مالی نوین، ۱۶ (۳)، ۷۵-۹۸.
- رضایی، م.، و ابراهیمی، ف. (۱۳۹۹). بررسی نسبت‌های مالی در پیش‌بینی بحران مالی شرکت‌ها. فصلنامه حسابداری و اقتصاد، ۱۴ (۱)، ۳۳-۵۶.
- کریمی، ن.، و جعفری، ح. (۱۴۰۲). کاربرد الگوریتم‌های فراابتکاری در بهینه‌سازی مدل‌های یادگیری ماشین. مجله هوش مصنوعی در مدیریت، ۷ (۲)، ۶۵-۸۸.
- موسوی، ع.، و احمدی، ر. (۱۳۹۸). پیش‌بینی ریسک مالی در بازار سرمایه ایران با استفاده از الگوریتم ژنتیک. فصلنامه پژوهش‌های مالی پیشرفته، ۱۲ (۴)، ۹۰-۱۱۲.
- نیکوکار، ا.، و مرادی، ک. (۱۴۰۰). نقش یادگیری ماشین در تحلیل داده‌های مالی. مجله علوم داده و اقتصاد، ۱۰ (۲)، ۵۵-۷۹.
- صادقی، ر.، و بهرامی، ف. (۱۴۰۳). مدل‌های ترکیبی در پیش‌بینی بحران مالی شرکت‌ها. فصلنامه مدیریت مالی هوشمند، ۵ (۱)، ۲۵-۴۸.
- یوسفی، م.، و قاسمی، ح. (۱۳۹۷). کاربرد شبکه‌های عصبی در تحلیل ریسک اعتباری. نشریه پژوهش‌های بانکی، ۹ (۳)، ۶۰-۸۲.
- مرادی، ک.، و شریفی، ع. (۱۳۹۶). تحلیل داده‌های مالی با روش‌های هوشمند. فصلنامه اقتصاد کاربردی، ۸ (۱)، ۴۰-۶۳.
- جعفری، ح.، و حسینی، س. (۱۴۰۲). بررسی عملکرد مدل‌های یادگیری ماشین در بازار سرمایه ایران. مجله مالی و سرمایه‌گذاری، ۱۳ (۲)، ۷۰-۹۵.
- ابراهیمی، م.، و رضایی، ر. (۱۳۹۸). کشف تقلب مالی در شرکت‌های بورسی. فصلنامه حسابداری نوین، ۱۱ (۴)، ۵۰-۷۲.
- بهرامی، ف.، و کریمی، ن. (۱۴۰۱). مقایسه مدل‌های آماری و هوش مصنوعی در پیش‌بینی ورشکستگی. نشریه مدیریت مالی، ۱۵ (۳)، ۸۰-۱۰۵.
- موسوی، س.، و احمدی، م. (۱۴۰۳). کاربرد SVM در تحلیل بازار سرمایه ایران. مجله اقتصاد مالی، ۱۷ (۱)، ۳۰-۵۲.
- رضایی، م.، و نیکوکار، ا. (۱۴۰۰). بهینه‌سازی پارامترهای مدل‌های یادگیری ماشین. فصلنامه داده کاوی مالی، ۶ (۲)، ۴۵-۶۸.

حسینی، ع.، و جعفری، ح. (۱۳۹۹). تحلیل ریسک اعتباری در نظام بانکی ایران. نشریه اقتصاد پولی و بانکی، ۱۰ (۳)، ۶۵-۸۷.
صادقی، ر.، و موسوی، س. (۱۴۰۲). یادگیری عمیق در پیش‌بینی بحران مالی. مجله هوش مصنوعی مالی، ۸ (۲)، ۵۵-۷۸.

کتاب‌ها

آذر، ع.، و مؤمنی، م. (۱۳۹۲). آمار و کاربرد آن در مدیریت. تهران: سمت.
سعیدی، م. (۱۳۹۴). مدیریت مالی پیشرفته. تهران: سمت.
رازانی، ح. (۱۳۹۶). مدیریت ریسک در مؤسسات مالی. تهران: نشر نی.
کریمی، ن. (۱۴۰۰). یادگیری ماشین در علوم مالی. تهران: دانشگاه تهران.
جعفری، ح. (۱۴۰۱). اقتصاد مالی و بازارهای سرمایه. تهران: نشر نی.
نیوکوکار، ا. (۱۳۹۵). بانکداری و نظام‌های پرداخت الکترونیک. تهران: دانشگاه تهران.
موسوی، ع. (۱۳۹۸). تحلیل داده در مدیریت مالی. تهران: سمت.
رضایی، م. (۱۴۰۲). روش‌های نوین پیش‌بینی مالی. تهران: انتشارات دانشگاه تهران.
بهرامی، ف. (۱۳۹۷). مدیریت مالی کاربردی. تهران: نشر نی.
حسینی، س. (۱۳۹۶). اصول تحلیل صورت‌های مالی. تهران: سمت.
صادقی، ر. (۱۴۰۰). داده کاوی در اقتصاد. تهران: دانشگاه تهران.
ابراهیمی، م. (۱۳۹۵). مدیریت سرمایه‌گذاری. تهران: سمت.
مرادی، ک. (۱۳۹۴). اقتصاد مالی. تهران: سمت.
یوسفی، م. (۱۳۹۹). تحلیل ریسک مالی. تهران: نشر نی.
کریمی، ن. (۱۴۰۲). هوش مصنوعی در اقتصاد. تهران: دانشگاه تهران.
جعفری، ح. (۱۳۹۸). بازارهای مالی پیشرفته. تهران: نشر نی.

اسناد و گزارش‌ها

بانک مرکزی جمهوری اسلامی ایران. (۱۴۰۱). گزارش شاخص‌های عملکرد نظام بانکی کشور. تهران: بانک مرکزی.
سازمان بورس و اوراق بهادار. (۱۴۰۲). گزارش سالانه بازار سرمایه ایران. تهران.
مرکز آمار ایران. (۱۴۰۰). گزارش تحولات اقتصادی و مالی کشور. تهران.
وزارت امور اقتصادی و دارایی. (۱۴۰۱). گزارش ثبات مالی کشور. تهران.
سازمان برنامه و بودجه کشور. (۱۴۰۲). گزارش شاخص‌های کلان اقتصادی. تهران.
بانک مرکزی جمهوری اسلامی ایران. (۱۴۰۲). گزارش وضعیت اعتباری و نقدینگی. تهران.
سازمان بورس و اوراق بهادار. (۱۴۰۱). گزارش تحلیل صنایع بورسی. تهران.
مرکز پژوهش‌های مجلس شورای اسلامی. (۱۴۰۰). گزارش ارزیابی نظام مالی کشور. تهران.

منابع انگلیسی

Articles

- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, 23(4), 589–609.
- Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4, 71–111.
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109–131.
- Vapnik, V. (1995). *The nature of statistical learning theory*. Springer.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.
- Smola, A. J., & Schölkopf, B. (2002). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199–222.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *IEEE International Conference on Neural Networks*.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems*. University of Michigan Press.
- Dorigo, M., & Stützle, T. (2004). *Ant colony optimization*. MIT Press.
- Mirjalili, S. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46–61.

- Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in Engineering Software*, 95, 51–67.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Goodfellow, I., et al. (2016). *Deep learning*. MIT Press.
- Chandola, V., et al. (2009). Anomaly detection: A survey. *ACM Computing Surveys*, 41(3), 1–58.
- Ngai, E. W. T., et al. (2011). Data mining techniques in financial fraud detection. *Decision Support Systems*, 50(3), 559–569.
- Reurink, A. (2018). Financial fraud: A literature review. *Journal of Economic Surveys*, 32(5), 1–25.

Additional Recent Works

- Salahi, M., et al. (2020). Generative adversarial networks in financial applications. *Neural Computing and Applications*.
- Ramos-Pérez, E., et al. (2020). Volatility modeling in financial markets. *Finance Research Letters*.
- Darvish, M., et al. (2025). Deep learning approaches in financial time series forecasting. *Expert Systems with Applications*.
- Loizou, A., & Petkov, N. (2026). Deep learning for financial volatility modeling. *Journal of Computational Finance*.
- D'Amico, G., et al. (2026). Multimodal learning for financial forecasting. *Journal of Financial Data Science*.
- Podobinski, M., & Chodzia, P. (2026). GAN-based financial forecasting improvements. *IEEE Access*.