



## مقایسه روش‌های مختلف انتخاب متغیرهای پیش‌بین برای پیش‌بینی بحران مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران

محمد نمازی<sup>۱</sup>

مصطفی کاظم‌نژاد<sup>۲</sup>

محمد مهدی نعمت‌الهی<sup>۳</sup>

تاریخ پذیرش: ۹۵/۲/۲۳

تاریخ دریافت: ۹۴/۱۲/۱۷

### چکیده

در پژوهش‌های انجام شده در زمینه پیش‌بینی بحران مالی و ورشکستگی، هدف و تأکید اصلی، ارائه مدل‌های مناسب و دقیق برای پیش‌بینی ورشکستگی بوده و کمتر به انتخاب متغیرهای پیش‌بین و روش‌های مناسب آن پرداخته شده است. بنابراین، پژوهش حاضر به بررسی و مقایسه سودمندی روش‌های مختلف انتخاب متغیرهای پیش‌بین در پیش‌بینی بحران مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران می‌پردازد. در این راستا، عملکرد روش‌های انتخاب متغیر، شامل آزمون  $t$ ، تحلیل ممیزی گام به گام، تحلیل عاملی، ریلیف، مبتنی بر روکشی و مبتنی بر بردارهای پشتیبان، بررسی و با هم مقایسه می‌شود. طبقه‌بندی کننده‌های استفاده شده نیز شامل شبکه‌های عصبی مصنوعی، ماشین بردار پشتیبان و آدابوست (بوستینگ) می‌باشد. به طور کلی، یافته‌های پژوهش حاکی از سودمندی استفاده از روش‌های انتخاب متغیر نسبت به عدم استفاده از این روش‌ها در پیش‌بینی بحران مالی و همچنین وجود تفاوت معنادار بین میزان سودمندی این روش‌هاست. به عبارت دیگر، در صورت استفاده از روش‌های انتخاب متغیرهای پیش‌بین، میانگین دقت افزایش و خطای نوع اول و دوم کاهش می‌یابد. افزون بر این، یافته‌های پژوهش حاکی از برتری روش انتخاب متغیر مبتنی بر روکشی نسبت به سایر روش‌های انتخاب متغیرهای پیش‌بین است.

**واژه‌های کلیدی:** پیش‌بینی بحران مالی، انتخاب متغیرهای پیش‌بین، شبکه‌های عصبی، ماشین بردار پشتیبان و آدابوست.

۱- استاد گروه حسابداری، دانشکده اقتصاد، مدیریت و علوم اجتماعی دانشگاه شیراز، شیراز، ایران Mnamazi@rose.shirazu.ac.ir

۲- دانشجوی دکتری حسابداری، دانشگاه شیراز، شیراز، ایران Mkazemi5166@Gmail.com

۳- دانشجوی دکتری هوش مصنوعی، دانشگاه صنعتی شاهرود، شاهرود، ایران Mmmematollahi@gmail.com

## ۱- مقدمه

سرمایه‌گذاران و اعتباردهندگان، تمایل زیادی برای پیش‌بینی بحران مالی و ورشکستگی شرکت‌ها دارند زیرا در صورت ورشکستگی، هزینه‌های زیادی به آن‌ها تحمیل می‌شود. افزون بر این، به دلیل این که بحران مالی اغلب مقدم و در بسیاری از موارد تسریع کننده ورشکستگی است، ایجاد یک مدل قوی و موفق برای شناسایی و پیش‌بینی شرکت‌های دارای بحران مالی که ممکن است ورشکسته شوند، در پیشگیری یا حداقل در کاهش پیشرفت فرآیند ورشکستگی، نقش بسزایی ایفا می‌کند (لیانو<sup>۱</sup>، ۲۰۰۴). در این راستا، نقش متغیرهای پیش‌بین بهینه و روش‌های انتخاب آن‌ها حائز اهمیت است، زیرا انتخاب متغیرهای بهینه به عنوان یک مرحله پیش‌پردازش (قبل از انجام پیش‌بینی)، یکی از مهم‌ترین مراحل فرآیند داده‌کاوی است که افزون بر فیلتر کردن متغیرهای نامربوط از داده‌های اولیه، منجر به بهبود عملکرد پیش‌بینی می‌شود (تسای، ۲۰۰۹: ۱۲۰). به‌رغم اهمیت انتخاب متغیرهای پیش‌بین در عملکرد پیش‌بینی بحران مالی و ورشکستگی، تاکنون پژوهش‌های اندکی در زمینه انتخاب متغیرهای پیش‌بین، روش‌های آن و مقایسه میزان سودمندی هر یک از این روش‌ها انجام شده است. در مقابل، در بسیاری از پژوهش‌های داخلی و خارجی انجام شده در زمینه ورشکستگی و بحران مالی، مرحله انتخاب متغیرهای پیش‌بین، نادیده گرفته شده و متغیرهای پیش‌بین بدون ضابطه و صرفاً با توجه به پژوهش‌های گذشته انتخاب شده است، که این امر به انتخاب متغیرهای پیش‌بین غیربهینه و در برخی موارد، متغیرهای پیش‌بین نامناسب منجر می‌شود. یافته‌های پژوهش لو<sup>۲</sup> (۲۰۱۰) نیز حاکی از آن است که انتخاب متغیرهای پیش‌بین و روش‌های آن، نسبت به انتخاب مدل پیش‌بینی، تاثیر بیشتری بر میانگین دقت پیش‌بینی دارد. با توجه به اهمیت روش‌های انتخاب متغیرهای پیش‌بین، پژوهش حاضر به بررسی و مقایسه این روش‌ها برای پیش‌بینی بحران مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران می‌پردازد. در این مقاله، پس از بیان مبانی نظری و روش‌های مختلف انتخاب متغیرهای پیش‌بین، پیشینه داخلی و خارجی ارائه می‌شود. در ادامه، روش انجام پژوهش و یافته‌های تجربی پژوهش، تشریح شده است. بخش آخر مقاله نیز به بحث و نتیجه‌گیری، ارائه پیشنهادها و محدودیت‌های مطالعه اختصاص دارد.

## ۲- مبانی نظری و مروری بر پیشینه پژوهش

## ۲-۱- تعریف و معیار سنجش بحران (درماندگی) مالی

فاستر<sup>۳</sup> (۱۹۸۶) بین "بحران مالی" و "ورشکستگی" تمایز قائل می‌شود و شرکت‌ها را به چهار دسته تقسیم می‌کند: شرکت‌های فاقد بحران مالی و غیرورشکسته، شرکت‌های دارای بحران مالی و غیرورشکسته، شرکت‌های فاقد بحران مالی ولی ورشکسته و در نهایت شرکت‌های دارای بحران مالی و ورشکسته. فاستر معتقد است که شرکت‌های دارای بحران مالی ولی غیرورشکسته می‌توانند مشکلات نقدینگی خود را از طریق تجدید ساختار عمده یا ترکیب با شرکت دیگری حل کنند. وی، بحران مالی را به‌عنوان مشکلات نقدینگی تعریف می‌کند که نمی‌توان آن را بدون تجدید در ساختار یا عملیات قابل ملاحظه، حل کرد. در این

پژوهش، مبنای درمانده مالی یا سالم بودن شرکت‌ها، شرط موجود در ماده ۱۴۱ قانون تجارت است. بر اساس این ماده، "اگر بر اثر زیان‌های وارده، حداقل نصف سرمایه شرکت از میان برود، هیئت مدیره مکلف است بلافاصله مجمع عمومی فوق‌العاده صاحبان سهام را دعوت نماید تا موضوع انحلال یا بقاء شرکت مورد شور و رأی واقع شود. هرگاه مجمع مزبور رأی به انحلال شرکت ندهد، باید در همان جلسه و با رعایت مقررات ماده ۶ این قانون، سرمایه شرکت را به مبلغ سرمایه موجود کاهش دهد." بنابراین، اگر شرکتی، مشمول شرط این ماده باشد، به‌عنوان درمانده مالی و در غیر این صورت به‌عنوان غیردرمانده مالی (سالم) قلمداد خواهد شد. این معیار در اغلب پژوهش‌های داخلی، به‌عنوان نمونه، راعی و فلاح‌پور (۱۳۸۷)، نیکومرام و پورزمانی (۱۳۸۸)، مشایخی و گنجی (۱۳۹۳)، قالی‌باف اصل و افشار (۱۳۹۳) و اعتمادی<sup>۴</sup> و همکاران (۲۰۰۹) نیز استفاده شده است.

## ۲-۲- انتخاب متغیرهای پیش‌بین و اهمیت آن در پیش‌بینی ورشکستگی

مرحله انتخاب متغیرهای پیش‌بین، عموماً قبل از استفاده از مدل‌های پیش‌بینی انجام می‌شود (تسای، ۲۰۰۹: ۱۲۰). با این وجود، در اغلب پژوهش‌های داخلی و خارجی انجام شده در زمینه ورشکستگی و بحران مالی، این مرحله نادیده گرفته شده و متغیرهای پیش‌بین به‌صورت نظام‌مند انتخاب نشده است، که این امر به انتخاب متغیرهای پیش‌بین غیربهبوده و در برخی موارد، متغیرهای پیش‌بین نامناسب منجر می‌شود. در این پژوهش‌ها، متغیرهای پیش‌بین، صرفاً با توجه به پژوهش‌های گذشته انتخاب شده است. در پژوهش‌های اندکی که در آن‌ها مرحله انتخاب متغیرهای پیش‌بین انجام شده است، از روش‌های ماتریس همبستگی (آتیا<sup>۵</sup>، ۲۰۰۱؛ تانگ<sup>۶</sup> و همکاران، ۲۰۰۴ و تسای<sup>۷</sup>، ۲۰۰۹)؛ تحلیل عاملی (شین و لی<sup>۸</sup>، ۲۰۰۲ و تسای، ۲۰۰۹)؛ آزمون t (هانگ<sup>۹</sup> و همکاران، ۲۰۰۴، شین و لی، ۲۰۰۲ و شین و همکاران، ۲۰۰۵)؛ تحلیل مؤلفه‌های اصلی (کانیاس<sup>۱۰</sup> و همکاران، ۲۰۰۵ و مین<sup>۱۱</sup> و لی، ۲۰۰۵)؛ تحلیل تشخیصی گام به گام (شین و لی، ۲۰۰۲، شین و همکاران، ۲۰۰۵ و تسای، ۲۰۰۹)؛ مجذور اتا (لو، ۲۰۱۰) و الگوریتم تکاملی (پویای) چندمنظوره (گاسپرکانها<sup>۱۲</sup> و همکاران، ۲۰۱۰) استفاده شده است. انتخاب متغیرهای مناسب جهت رسیدن به بهترین نتیجه در طبقه‌بندی داده‌ها از مباحث چالش برانگیز در دو دهه اخیر بوده است. از دیدگاه تئوری، یادگیری از تعداد متغیرهای پیش‌بین بیشتر باعث می‌شود تا دقت پیش‌بینی بالا رود. با این وجود، شواهد تجربی بیانگر آن است که این امر همواره صادق نیست؛ زیرا تمام متغیرها، برای تشخیص و پیش‌بینی طبقه داده‌ها مهم نیستند و یا برخی از آن‌ها اساساً با طبقه داده‌ها بی‌ارتباط هستند (داس و نایاک<sup>۱۳</sup>، ۱۹۹۰ و لیندبام<sup>۱۴</sup> و همکاران، ۲۰۰۴). با توجه به این‌که عامل‌های بسیاری، از جمله کیفیت داده‌ها، در موفقیت یک الگوریتم یادگیری موثر است، اگر داده‌ها حاوی ویژگی‌ها و یا اطلاعات تکراری و نامربوط باشند و یا حاوی اطلاعات دارای پارازیت و نامطمئن باشند، اخذ دانش از آن داده‌ها مشکل می‌گردد (هال<sup>۱۵</sup>، ۲۰۰۰). افزون بر این، کاهش تعداد متغیرهای پیش‌بین نامربوط یا اضافی، علاوه بر کاهش زمان اجرای الگوریتم‌های آموزشی، به مفهومی‌تر منجر می‌شود. سایر مزایای بالقوه انتخاب متغیرهای پیش‌بین شامل تسهیل درک و تجسم داده‌ها، کاهش الزامات اندازه‌گیری و ذخیره اطلاعات، مقاومت در برابر اضافه‌بار ابعاد<sup>۱۶</sup> و بهبود

عملکرد پیش‌بینی و فراهم کردن بینش بهتر در مورد مفهوم زیربنایی از طبقه‌بندی دنیای واقعی است (تسای، ۲۰۰۹).

با توجه به نحوه استفاده از الگوریتم یادگیری در فرآیند انتخاب متغیرهای پیش‌بین، الگوریتم‌های انتخاب متغیرهای پیش‌بین به دو دسته کلی تقسیم می‌شوند، روش‌های مبتنی بر فیلتر<sup>۱۷</sup> و روش‌های بر روشی<sup>۱۸</sup> (کوهاوی و جان، ۱۹۹۷). در روش‌های مبتنی بر فیلتر، الگوریتم انتخاب متغیرهای پیش‌بین، مستقل از الگوریتم مورد استفاده برای طبقه‌بندی داده‌ها، متغیرهای پیش‌بین را انتخاب می‌کند؛ به همین علت این روش‌ها از نظر محاسباتی کارا می‌باشند و برای پردازش داده‌های با ابعاد زیاد مناسب هستند. در مقابل، روش‌های مبتنی بر روشی، آن دسته از روش‌های انتخاب متغیرهای پیش‌بین هستند که از الگوریتم یادگیری خاصی در طول فرآیند انتخاب متغیرهای پیش‌بین، برای ارزیابی هر زیرمجموعه از متغیرهای پیش‌بین، استفاده می‌کنند. به همین علت این روش‌ها برای الگوریتم یادگیری مورد نظر، نتایج بهتری تولید می‌کنند اما هزینه محاسباتی بالاتری نسبت به روش‌های فیلتر دارند و با توجه به این که از یک الگوریتم یادگیری خاص برای ارزیابی استفاده می‌کنند، عمومیت کمتری نیز دارند (کوهاوی و جان، ۱۹۹۷). در این پژوهش از هر دو روش استفاده می‌شود. در بخش روش پژوهش به تشریح روش‌های مورد استفاده پرداخته می‌شود.

### ۲-۳- پیشینه پژوهش

تکنیک‌های آماری تک‌متغیری، از اولین تکنیک‌هایی بودند که برای پیش‌بینی ورشکستگی و بحران مالی مورد استفاده قرار گرفتند. با استفاده از این نوع تحلیل می‌توان دقت پیش‌بینی نسبت‌های مالی مختلف را مورد بررسی قرار داد. در این فن‌ها هر بار یکی از نسبت‌ها بررسی می‌شود. به عنوان نمونه در سال ۱۹۶۶ بیور<sup>۱۹</sup> به منظور ارزیابی توان نسبت‌های مالی در پیش‌بینی بحران مالی از تحلیل تک‌متغیری استفاده کرد. در این پژوهش ۳۰ نسبت مالی انتخاب و سپس این نسبت‌ها به شش گروه، طبقه‌بندی شد. یافته‌های پژوهش بیور حاکی از آن بود که تفاوت معناداری بین نسبت‌های مالی شرکت‌های درمانده مالی و سالم وجود دارد. افزون بر این، قدرت برخی نسبت‌های مالی به‌ویژه نسبت جریان‌های نقدی به کل بدهی‌ها، در پیش‌بینی بحران مالی زیاد بود. آلتمن<sup>۲۰</sup> (۱۹۶۸) تحلیل تک‌متغیره را مورد انتقاد قرار داده و تحلیل ممیزی چندگانه که در آن چندین نسبت مالی، همزمان در پیش‌بینی ورشکستگی بررسی می‌شد را پیشنهاد کرد. پژوهش‌های زیادی با استفاده از مدل‌های آماری و با متغیرهای مختلف در زمینه پیش‌بینی ورشکستگی (به عنوان نمونه، دیکن<sup>۲۱</sup>، ۱۹۷۲؛ فالمر<sup>۲۲</sup>، ۱۹۸۴ و زیمسکی<sup>۲۳</sup>، ۱۹۸۴) انجام شد. در بورس اوراق بهادار تهران نیز در پژوهش‌های زیادی (به عنوان نمونه، مهرانی و همکاران، ۱۳۸۴ و رهنمای رودپشتی و همکاران، ۱۳۸۸) به پیش‌بینی بحران مالی با استفاده از مدل‌های آماری پرداخته شده است.

با توجه به مشکلات روش‌های خطی آماری (از قبیل ماهیت خطی، وابستگی به توزیع آماری و از پیش مشخص کردن مدل) پژوهش‌های زیادی بر استفاده از تکنیک‌های هوش مصنوعی (شبکه‌های عصبی، ماشین بردار پشتیبان، الگوریتم ژنتیک و ...) و مقایسه عملکرد آن‌ها با روش‌های آماری تأکید داشته‌اند.

به‌عنوان نمونه، ادم و شارادا<sup>۲۴</sup> (۱۹۹۰) برای اولین بار از شبکه‌های عصبی مصنوعی برای پیش‌بینی ورشکستگی استفاده کردند. یافته‌های پژوهش آنان حاکی از دقت و توان پیش‌بینی بهتر شبکه‌های عصبی مصنوعی نسبت به تحلیل ممیزی چندگانه بود. یافته‌های پژوهش‌های راعی و فلاح پور (۱۳۸۳)، پورزمانی و همکاران (۱۳۸۹)، نیکبخت و شریفی (۱۳۸۹) و نمازی و صادق زاده (۲۰۱۵) در بورس اوراق بهادار تهران نیز حاکی از عملکرد بهتر این تکنیک هوش مصنوعی نسبت به روش‌های خطی آماری بود.

مین و لی (۲۰۰۵) با استفاده از ماشین بردار پشتیبان، به پیش‌بینی ورشکستگی شرکت‌ها پرداختند. یافته‌های پژوهش آن‌ها نشان داد که ماشین بردار پشتیبان نسبت به مدل‌های آماری سنتی از عملکرد بهتری برخوردار است. یافته‌های پژوهش شین و همکاران (۲۰۰۵) نیز حاکی از عملکرد بهتر ماشین بردار پشتیبان نسبت به شبکه‌های عصبی مصنوعی بود. یافته‌های پژوهش راعی و فلاح پور (۱۳۸۷) در بورس اوراق بهادار تهران نیز نتایج پژوهش مین و لی (۲۰۰۵) را تأیید می‌کرد.

پژوهش‌های زیادی با استفاده از سایر روش‌های هوش مصنوعی از قبیل الگوریتم ژنتیک (شین و لی، ۲۰۰۲، اعتمادی و همکاران، ۲۰۰۹ و فدایی‌نژاد و اسکندری، ۱۳۹۰)؛ تحلیل پوششی داده‌ها (فرناندز-کاسترو و اسمیت<sup>۲۵</sup>، ۱۹۹۴، موسوی شیری و طبرستانی، ۱۳۸۸ و اقدامی و همکاران، ۱۳۹۴)، شبکه‌های بیز (سارکر و سریرام<sup>۲۶</sup>، ۲۰۰۱ و سعیدی و آقایی، ۱۳۸۸) پرداختند. یافته‌های اغلب این پژوهش‌ها حاکی از برتری روش‌های هوش مصنوعی نسبت به مدل خطی آماری بود.

با شناخته شدن مزایای روش‌های تجمیعی نسبت به طبقه‌کننده‌های انفرادی، پژوهش‌هایی در این زمینه انجام شد. آلفارو<sup>۲۷</sup> و همکاران (۲۰۰۸) به مقایسه دقت مدل تجمیعی بوستینگ و شبکه‌های عصبی مصنوعی در پیش‌بینی ورشکستگی شرکت‌های اروپایی پرداختند. یافته‌های این پژوهش حاکی از آن بود که روش بوستینگ خطای تعمیم‌پذیری را نسبت به شبکه‌های عصبی مصنوعی کاهش می‌دهد. یافته‌های پژوهش هانگ و چن<sup>۲۸</sup> (۲۰۰۹)، کیم و کانگ<sup>۲۹</sup> (۲۰۱۰) و سان<sup>۳۰</sup> و همکاران (۲۰۱۱) نیز حاکی از عملکرد بهتر روش‌های تجمیعی نسبت به مدل‌های انفرادی بود.

تأکید بیشتر پژوهش‌های انجام شده بر انتخاب مدل‌های بهینه برای پیش‌بینی بوده و کمتر به انتخاب متغیرهای بهینه برای پیش‌بینی تأکید شده است و به طور کلی، یافته‌های اغلب این پژوهش‌ها، حاکی از برتری روش‌های هوش مصنوعی نسبت به مدل‌های خطی آماری و همچنین عملکرد بهتر روش‌های تجمیعی نسبت به مدل‌های انفرادی است. به‌عنوان نمونه، تسای (۲۰۰۹) به مقایسه پنج روش متداول انتخاب متغیر مورد استفاده در پیش‌بینی ورشکستگی پرداخت. یافته‌های پژوهش حاکی از عملکرد بهتر روش آزمون t نسبت به سایر روش‌های انتخاب متغیر بود. گاسپر-کانها و همکاران (۲۰۱۰) از یک الگوریتم تکاملی چندمنظوره برای انتخاب متغیرهای پیش‌بین در پیش‌بینی ورشکستگی استفاده کردند. یافته‌های پژوهش حاکی از آن بود که الگوریتم تکاملی چندمنظوره یک رویکرد کارا برای انتخاب متغیرهاست. جاردين<sup>۳۱</sup> (۲۰۱۰) به ارزیابی دقت پیش‌بینی مدل‌های طراحی شده با استفاده از روش‌های طبقه‌بندی مختلف (با تأکید بر تکنیک مورد استفاده برای انتخاب متغیرها)، پرداخت و رابطه بین ساختار مدل‌ها و

توانایی آن‌ها برای پیش‌بینی صحیح ورشکستگی را مورد بررسی قرار داد. یافته‌های پژوهش بیانگر آن بود که پیش‌بینی شبکه عصبی با استفاده از متغیرهای منتخب، نسبت به مجموعه متغیرهای انتخابی براساس ضابطه استفاده شده در ادبیات مالی، از عملکرد بهتری برخوردار است. ونگ<sup>۳۲</sup> و همکاران (۲۰۱۴) نیز به بررسی سودمندی انتخاب متغیرهای پیش‌بین در روش تجمیعی بوستینگ برای پیش‌بینی ورشکستگی پرداختند. یافته‌های پژوهش حاکی از سودمندی متغیرهای انتخاب شده در پیش‌بینی با استفاده از روش تجمیعی بوستینگ بود. همچنین، لیانگ<sup>۳۳</sup> و همکاران (۲۰۱۵) به بررسی سودمندی انتخاب متغیرهای پیش‌بین بر پیش‌بینی بحران مالی پرداختند. یافته‌های این پژوهش حاکی از آن بود که در اغلب موارد، انتخاب متغیرهای پیش‌بین باعث بهبود عملکرد پیش‌بینی می‌شود.

تاکنون پژوهشی که به بررسی و مقایسه روش‌های مختلف انتخاب متغیرهای پیش‌بین در زمینه پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداخته باشد، مشاهده نشد. با این وجود، در برخی پژوهش‌ها از روش تحلیل ممیزی گام به گام (پورزمانی و کلانتری، ۱۳۹۲، اعتمادی و همکاران، ۲۰۰۹) و آزمون t (عرب مازار یزدی و صفرزاده، ۱۳۸۸) استفاده شده است. با توجه به کاستی‌های پژوهشی موجود در بورس اوراق بهادار تهران و تأکید پژوهش‌ها بر مدل‌های بهینه پیش‌بینی و انتخاب متغیرها صرفاً براساس پژوهش‌های گذشته، پژوهش حاضر به بررسی سودمندی و مقایسه روش‌های مختلف انتخاب متغیر می‌پردازد. افزون بر این، با توجه به انجام نشدن پژوهشی با استفاده از روش‌های تجمیعی، در این پژوهش از طبقه‌بندی کننده تجمیعی بوستینگ برای پیش‌بینی بحران مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران استفاده و عملکرد آن با شبکه‌های عصبی و ماشین بردار پشتیبان مقایسه شده است.

### ۳- روش شناسی پژوهش

پژوهش حاضر، کاربردی و طرح آن از نوع شبه‌تجربی است. جامعه آماری این پژوهش، کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران طی دوره زمانی ۱۳۸۰ تا ۱۳۹۳ است. با توجه به این‌که ملاک تشخیص درماندگی مالی شرکت‌ها در این پژوهش ماده ۱۴۱ قانون تجارت است، ابتدا فهرستی از شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران که بین سال‌های ۱۳۸۰ تا ۱۳۹۳ دچار درماندگی مالی شده بودند (مشمول ماده ۱۴۱ قانون تجارت بودند) تهیه شد. از بین این ۱۱۰ شرکت، ۹۸ شرکت تولیدی که کلیه اطلاعات مورد نیاز آن‌ها در دسترس بود به‌عنوان شرکت‌های درمانده مالی انتخاب شد. در ادامه، ۹۸ شرکت سالم (فاقد درماندگی مالی) از بین شرکت‌های تولیدی و سالم پذیرفته شده در بورس اوراق بهادار تهران، که کلیه اطلاعات مورد نیاز برای انجام پژوهش را به بورس اوراق بهادار ارائه کرده بودند به‌صورت تصادفی انتخاب شد.

در این پژوهش برای جمع‌آوری داده‌ها و اطلاعات از روش‌های کتابخانه‌ای و میدانی استفاده شده است. مبانی نظری پژوهش از کتب، مجلات و سایت‌های تخصصی فارسی و لاتین گردآوری شد و داده‌های مالی

مورد نیاز با مراجعه به سایت سازمان بورس اوراق بهادار تهران، صورت‌های مالی شرکت‌ها و همچنین با استفاده از نرم‌افزارهای تدبیرپرداز و ره‌آورد نوین گردآوری شده است. در مرحله اول با بررسی ادبیات و پیشینه پژوهش، حدود ۱۵۰ متغیر پیش‌بین اولیه، شناسایی شد. از بین متغیرهای شناسایی شده، ۶۹ متغیری که بیشتر در ادبیات ورشکستگی استفاده شده و داده‌های مورد نیاز برای سنجش آن‌ها از طریق پایگاه‌های اطلاعاتی ذکر شده در دسترس بود، انتخاب شد. در این راستا، سعی شد که هم متغیرهای حسابداری (اقدام مبتنی بر ترانزنامه، صورت سود و زیان و صورت جریان وجوه نقد) و هم متغیرهای بازار استفاده و محتوای اطلاعاتی آن‌ها مدنظر قرار گیرد. بنابراین، ابعاد سودآوری، کارایی، اهرم مالی، نقدینگی، نسبت‌های مبتنی بر هر سهم، نسبت‌های مبتنی بر جریان وجوه نقد و نسبت‌های بازار در نظر گرفته شده است. جدول ۱ میانگین این متغیرها را در شرکت‌های درمانده و سالم نشان می‌دهد. در ادامه، با استفاده از روش‌های مختلف انتخاب متغیر ریلیف<sup>۲۴</sup>، تحلیل عاملی، آزمون t، تحلیل ممیزی گام به گام، مبتنی بر روش‌های مختلف انتخاب متغیرهای پیش‌بین از بین ۶۹ متغیر ذکر شده، متغیرهای بهینه در هر روش انتخاب شده است (سه روش اول با استفاده از نرم‌افزار SPSS نسخه ۱۹ و سه روش دوم با استفاده از نرم‌افزار Weka نسخه ۳-۶ انجام شده است).

روش انتخاب متغیر ریلیف از جمله روش‌های انتخاب متغیر مبتنی بر معیار فاصله است. در ریلیف، وزنی که میزان ارتباط هر متغیر پیش‌بین را با طبقه نشان می‌دهد، توسط فاصله اقلیدسی بین نمونه‌ها تعیین می‌شود و وزن هر متغیر پیش‌بین نشان‌دهنده قابلیت جداسازی طبقه‌ها توسط آن متغیر پیش‌بین می‌باشد. در این روش، اگر یک متغیر پیش‌بین به ازای نمونه‌های درون یک طبقه، مقدار یکسان و به ازای نمونه‌های دیگر طبقه‌ها مقادیر مختلفی داشته باشد، وزن بالاتری می‌گیرد. ریلیف از بین داده‌های آموزشی یک نمونه را به صورت تصادفی انتخاب می‌کند و سپس فاصله اقلیدسی آن نمونه تا نزدیک‌ترین نمونه از طبقه مشابه و نزدیک‌ترین نمونه از طبقه متفاوت را به دست می‌آورد و سپس این فاصله‌ها را برای به روز کردن وزن هر متغیر به کار می‌برد. در نهایت، الگوریتم آن دسته از متغیرهای پیش‌بین را انتخاب می‌کند که وزن آن‌ها از یک حد آستانه‌ای از پیش تعریف‌شده توسط کاربر، بیشتر است (کرا و رندل، ۱۹۹۲ و آتیا، ۲۰۰۱). ریلیف از جمله روش‌های انتخاب متغیرهای پیش‌بین فیلتر است که اساساً با رتبه‌بندی نزولی متغیرهای پیش‌بین کار می‌کند و به علت سادگی و موثر بودن در افزایش صحت و دقت طبقه‌بندی در بسیاری از کاربردها استفاده می‌شود. رتبه‌ای که ریلیف به هر متغیر پیش‌بین می‌دهد بر اساس میزان نقش متغیرهای پیش‌بین در جداسازی نمونه‌های متفاوت همسایه است. این الگوریتم برای هر نمونه آموزشی به دنبال نزدیک‌ترین همسایه که با آن هم طبقه است می‌گردد که به این نزدیک‌ترین همسایه "نزدیک‌ترین برخورد"<sup>۲۵</sup> گفته می‌شود. سپس نزدیک‌ترین همسایه که طبقه آن با طبقه نمونه آموزش مخالف است را پیدا می‌کند که به این همسایه "نزدیک‌ترین خطا"<sup>۲۶</sup> گفته می‌شود. رتبه‌ای که به هر متغیر پیش‌بین داده می‌شود بر اساس نسبت مجموع فاصله نمونه‌های آموزشی تصویر شده روی هر متغیر پیش‌بین از نزدیک‌ترین برخورد همسایه برای

هر نمونه آموزشی به مجموع فاصله نزدیک‌ترین همسایه خطا برای هر نمونه آموزشی است (کرا و رندل، ۱۹۹۲ و آتیا، ۲۰۰۱).

تحلیل عاملی به بررسی همبستگی درونی تعداد زیادی از متغیرها می‌پردازد و در نهایت آن‌ها را در قالب عامل‌های عمومی محدودی دسته بندی کرده و تبیین می‌کند. در تحلیل عاملی کلیه متغیرها به‌طور همزمان مد نظر قرار می‌گیرند و هر یک از متغیرها به عنوان یک متغیر وابسته لحاظ می‌گردد (کلانتری، ۱۳۸۵). در آزمون t مستقل، متغیرهایی انتخاب می‌شود که تفاوت معناداری بین میانگین این متغیرها در دو گروه درمانده و غیردرمانده مالی وجود داشته باشد (تسای، ۲۰۰۹).

زمانی که از رگرسیون برای ساخت مدل استفاده می‌شود، یک تکنیک متداول برای جستجوی بهترین ترکیب متغیرهای پیش‌بین، رگرسیون گام به گام است. هر چند تفاوت‌هایی وجود دارد، رویه اساسی جستجوی بهترین متغیر پیش‌بین و اضافه کردن متغیرهایی است که ضوابط مشخصی را احراز می‌کنند. نتیجه، ترکیبی از متغیرهای پیش‌بین خواهد بود که همگی دارای ضرایب معنادار خواهند بود (تسای، ۲۰۰۹).

یکی از روش‌های انتخاب متغیرهای پیش‌بین مشهور، روش انتخاب متغیر مبتنی بر روشی برای انتخاب زیرمجموعه‌ای از متغیرهاست. هر روش انتخاب متغیر برای انتخاب متغیرهای بهینه به یک فضای جستجو، عملگرها، یک موتور جستجو و یک تابع ارزیابی نیاز دارد. در این روش از دقت ناشی از روایی متقابل<sup>۳۷</sup> جهت تابع ارزیابی استفاده می‌شود. همچنین از فضای جستجوی معمولی به همراه عملگرهای اضافه کردن و کم کردن بر پایه دو موتور جستجوی تپه نوردی<sup>۳۸</sup> و اولین بهینه<sup>۳۹</sup> استفاده می‌شود (کوهاوی و جان<sup>۴۰</sup>، ۱۹۹۷).

حذف بازگشتی متغیر<sup>۴۱</sup> تکنیکی است که بر تعداد زیادی متغیر اعمال شده و تلاش می‌کند تا تعداد متغیرهای انتخاب شده برای طبقه‌بندی را بر طبق اصول زیر کاهش دهد: یک طبقه‌بندی کننده بر روی قسمتی از داده‌ها آموزش داده می‌شود و متغیرها بر اساس معیارهایی رتبه-بندی می‌شوند.

برخی از متغیرها بر اساس قانون از پیش تعریف شده، انتخاب یا حذف می‌شوند. طبقه‌بندی کننده دوباره آموزش می‌بیند و متغیرها دوباره رتبه‌بندی می‌شوند. این الگوریتم تا جایی که به یک حالت پایدار (مانند مقدار خاصی از خطای طبقه‌بندی) برسد، ادامه پیدا می‌کند. گایان<sup>۴۲</sup> و همکاران توانستند با اعمال ماشین بردار پشتیبان<sup>۴۳</sup> بر روی تکنیک حذف بازگشتی متغیر، روشی را برای انتخاب ژن معرفی کنند که در مقایسه با سایر روش‌های انتخاب متغیر، از لحاظ بیش‌برازش<sup>۴۴</sup>، مقاوم‌تر است (گایان و همکاران، ۲۰۰۲).



جدول ۱- متغیرهای استفاده شده و مقایسه میانگین آن‌ها در شرکت‌های درمانده مالی و سالم

#	متغیر	میانگین درمانده	میانگین سالم	#	متغیر	میانگین درمانده	میانگین سالم
1	(Ca+STI)/CL	0.042	0.141	2	NI/SE	-0.076	0.365
3	(R+Inv)/TA	0.608	0.506	4	NI/TA	-0.007	0.162
5	P/S	0.466	0.206	6	OCF	4872.895	576490.6
7	R/S	0.516	0.314	8	OCF/SE	0.172	0.445
9	Ca/CL	0.029	0.071	10	OCF/CL	0.027	0.452
11	Ca/TA	0.020	0.031	12	OCF/IE	.694	43026.79
13	CGS/Inv	2.387	306.064	14	OCF/S	0.064	0.249
15	CA/CL	1.041	1.350	16	OCF/TA	0.024	0.181
17	CA/S	1.212	0.765	18	OCF/TL	0.025	0.379
19	CA/TA	0.690	0.623	20	OCF/NI	6.812	1.046
21	CL/SE	4.574	1.599	22	OCF/OI	-0.883	1.202
23	CL/TA	0.682	0.499	24	ORPS	5428.80	5832.29
25	CL/TL	0.852	0.871	26	OI/S	0.025	0.275
27	D/CS	0.117	0.729	28	OI/TA	0.021	0.202
29	D/NI	0.493	0.229	30	PIC/SE	0.967	0.467
31	EPS	98.461	1039.404	32	P/OCF	-0.342	0.148
33	EBIT/IE	-26.515	4260.17	34	QA/CL	0.469	0.759
35	EBIT/S	-0.122	0.232	36	QA/Inv	2.253	2736.354
37	EBIT/TA	-0.054	0.164	38	QA/TA	0.321	0.340
39	FA/(SE+LTD)	0.857	0.556	40	R/Inv	4.956	144.564
41	FA/TA	0.310	0.377	42	RE/Inv	4.593	2766.434
43	GP/S	0.128	0.334	44	RE/SC	0.092	1.304
45	IE/GP	1.441	0.149	46	RE/TA	-0.019	0.209
47	IE/S	0.101	0.033	48	S/Ca	120.078	67.968
49	IE/TE	0.092	0.042	50	S/FA	4.729	5.622
51	Inv/WC	-1.128	0.147	52	S/SE	4.187	2.510
53	Inv/S	0.562	0.290	54	S/TA	0.664	0.865
55	LTD/SE	0.672	0.199	56	SE/TA	0.204	0.431
57	LTD/TA	0.114	0.069	58	SE/TL	0.279	0.931
59	MVE/TA	0.407	0.746	60	Size(log TA)	12.052	13.355
61	MVE/TL	0.535	1.673	62	TIBL/TL	0.147	0.128
63	MVE/SE	2.194	1.709	64	TL/TA	0.796	0.569
65	NAPS	1449.95	2489.42	66	WC/S	-0.163	0.123
67	NI/GP	-1.697	0.622	68	WC/TA	0.008	0.124
69	NI/S	-0.026	0.227				

CA: Current assets, NI: Net income, Ca: Cash, OI: Operating income, CL: Current liabilities, QA: Quick assets, PIC: Paid in Capital, R: Receivables, EBIT: Earnings before interest& tax, RE: Retained earnings, FA: Fixed assets S: Sales, GP: Gross profit, SC: Stock capital, IE: Interest expenses, SE: Shareholders' equity, Inv: Inventory, STI: Short term Investment, LA: Liquid assets, TA: Total assets, LTD: Long term debt, TL: Total liabilities, MVE: Market value of equity, WC: Working capital, OCF: Operating cash flow, P: Stock price per share, D: Dividend, NAPS: Net Asset per Share

منبع: یافته‌های پژوهشگر

در این پژوهش، روش تحلیل تشخیصی (رگرسیون) گام به گام، منجر به انتخاب ده متغیر بهینه شد. روش‌های انتخاب متغیر ریلیف، مبتنی بر روکشی و مبتنی بر بردارهای پشتیبان نیز کلیه متغیرهای پیش‌بین را رتبه‌بندی می‌کند. به منظور قابلیت مقایسه بهتر با روش رگرسیون گام به گام، از ده متغیر اول (بهتر) رتبه‌بندی شده در این روش‌ها استفاده می‌شود که این متغیرها نیز به ترتیب رتبه در جدول شماره ۲ ارائه شده است. در روش آزمون t نیز ۵۲ متغیر، معنادار و مربوط شناسایی شدند. روش تحلیل عاملی نیز منجر به استخراج ۱۸ عامل گردید. شایان ذکر است که در این پژوهش، از داده‌های یک سال قبل شرکت‌ها برای پیش‌بینی درماندگی مالی استفاده شده است.

جدول ۲: متغیرهای منتخب هر روش انتخاب متغیر

روش انتخاب ردیف	گام به گام	ریلیف	مبتنی بر روکشی	مبتنی بر بردارهای پشتیبان
۱	(Ca+STI)/CL	SE/TA	RE/TA	RE/TA
۲	CL/SE	TL/TA	NI/TA	SE/TA
۳	D/CS	RE/TA	RE/I	Size
۴	D/NI	CL/TA	EBIT/TA	NI/TA
۵	NAPS	OI/TA	EBIT/S	CA/S
۶	RE/TA	NI/TA	OI/TA	TL/TA
۷	S/TA	EBIT/TA	EBIT/IE	OCF/TA
۸	Size	Size	RE/SC	OI/TA
۹	WC/TA	CL/SE	D/NI	EBIT/TA
۱۰	COGS/I	OI/S	NI/S	D/NI

منبع: یافته‌های پژوهشگر

در این پژوهش از طبقه‌بندی‌کننده‌های شبکه‌های عصبی مصنوعی، ماشین بردار پشتیبان و آداپوست (بوستینگ)<sup>۴۵</sup> در نرم‌افزار Weka استفاده شده است. دلیل استفاده از سه طبقه‌بندی‌کننده، امکان کسب نتایج تجربی قابل مقایسه است. در سال ۱۹۶۵ وپنیک<sup>۴۶</sup> گامی بسیار مهم در طراحی طبقه‌بندی‌کننده‌ها برداشت. وی نظریه آماری یادگیری را به صورت مستحکم‌تری بنا نهاد و ماشین‌های بردار پشتیبان را بر این اساس ارائه داد. ماشین بردار پشتیبان الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابرصفحه را حاصل می‌کنند. حداکثر کردن حاشیه ابر صفحه منجر به حداکثر شدن تفکیک بین طبقات می‌شود. به نزدیک‌ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان اطلاق می‌گردد. تنها از این بردارها (نقاط) برای مشخص کردن مرز بین طبقات استفاده می‌شود (راعی و فلاح پور، ۱۳۸۷).

در دهه اخیر استفاده زیادی از شبکه‌های عصبی مصنوعی برای پیش‌بینی ورشکستگی شرکت‌ها شده است. یک شبکه عصبی، شامل مجموعه‌ای از نرون‌های به هم متصل می‌باشد که به هر مجموعه از این نرون‌ها یک لایه گفته می‌شود. نقش نرون‌ها در شبکه‌های عصبی، پردازش اطلاعات است. این امر در شبکه‌های عصبی مصنوعی به وسیله یک پردازشگر ریاضی که همان تابع فعال‌سازی است، انجام می‌شود. یک تابع فعال‌سازی، براساس نیاز خاص مسأله‌ای که قرار است به وسیله شبکه عصبی حل شود، از سوی طراح انتخاب می‌شود. ساده‌ترین شکل شبکه، فقط دو لایه دارد. لایه ورودی و لایه خروجی شبکه شبیه یک سیستم ورودی-خروجی عمل می‌کند و ارزش نرون‌های ورودی را برای محاسبه ارزش نرون خروجی مورد استفاده قرار می‌دهد (منه‌اج، ۱۳۷۷). در این پژوهش از شبکه‌های عصبی پرسپترون چندلایه با الگوریتم آموزشی پس‌انتشار خطا استفاده شده است.

یکی از طبقه‌بندی‌کننده‌هایی که در چند سال اخیر مورد توجه قرار گرفته، استفاده از ترکیب چند طبقه‌بندی‌کننده است. این نوع طبقه‌بندی‌کننده‌ها که با نام "طبقه‌بندی‌کننده‌های تجمیعی" شناخته می‌شوند، بر مبنای تصمیم‌گیری چند خبره در مقابل یک خبره عمل می‌کنند. با استفاده از طبقه‌بندی‌کننده‌های تجمیعی، تصمیم‌های اتخاذ شده قابل اطمینان‌تر خواهد بود. یکی از طبقه‌بندی‌کننده‌های تجمیعی، بوستینگ می‌باشد. مفهوم کلی این طبقه‌بندی‌کننده، ایجاد یک طبقه‌بندی‌کننده قوی با استفاده از چند طبقه‌بندی‌کننده ساده و ضعیف است که به صورت خطی کنار یکدیگر قرار می‌گیرند. در طبقه‌بندی‌کننده‌های تجمیعی، که در آن چند طبقه‌بندی‌کننده به صورت سریالی در کنار هم قرار می‌گیرند به داده‌هایی که به صورت غلط توسط طبقه‌بندی‌کننده پیشین برچسب زده شود، در طبقه‌بندی‌کننده بعدی وزن بیشتری داده می‌شود. با انجام این عمل، طبقه‌بندی‌کننده‌ای که در ادامه قرار دارد سعی می‌کند که به داده‌هایی که در طبقه‌بندی‌کننده‌های قبلی اشتباه برچسب زده شده‌اند بیشتر توجه کند و به صورت ضمنی سعی در جداسازی نواحی که در طبقه‌بندی‌کننده‌های قبلی اشتباه ایجاد شده‌اند نماید (آل‌فارو و همکاران، ۲۰۰۸).

در این پژوهش، به منظور بررسی تعمیم‌پذیری پیش‌بینی‌های انجام شده توسط طبقه‌بندی‌کننده‌ها از روایی متقابل ۱۰ بخشی<sup>۴۷</sup> استفاده می‌شود. روایی متقابل ۱۰ بخشی برای برآورد نرخ خطای واقعی کاملاً قابل اتکا و کافی است (هو<sup>۴۸</sup>، ۲۰۱۰). در این روش، نمونه اصلی به ۱۰ دسته نمونه فرعی مختلف تقسیم می‌شود. در طبقه‌بندی، ۹ نمونه فرعی به عنوان نمونه‌های آموزشی استفاده می‌شود و نمونه فرعی باقی‌مانده به عنوان نمونه آزمایشی، مورد آزمون قرار می‌گیرد. این شیوه تا آن جا تکرار می‌شود که هر یک از ۱۰ نمونه فرعی به عنوان نمونه آزمایشی مورد آزمون قرار گیرد. در این پژوهش، روایی متقابل ۱۰ بخشی، با استفاده از اجزای مختلف مجموعه داده‌ها، به طور مستقل، ۱۰ بار انجام شده است (روایی متقابل ۱۰ بخشی با ۱۰ بار تکرار).

به منظور مقایسه عملکرد روش‌های مختلف انتخاب متغیرهای پیش‌بین، از معیارهای میانگین دقت و خطاهای نوع اول و دوم استفاده می‌شود. به عبارت دیگر، میانگین دقت پیش‌بینی بحران مالی و خطای نوع اول و دوم با استفاده از هر دسته از متغیرهای انتخاب شده توسط هر یک از روش‌های انتخاب متغیر مقایسه

می‌شود. در این راستا، از طبقه‌بندی‌کننده‌های شبکه‌های عصبی مصنوعی، ماشین بردار پشتیبان و بوستینگ استفاده می‌شود. خطای نوع اول، به معنی اشتباه عدم رد فرض صفر است، زمانی که فرض مقابل، حالت صحیح طبیعت است. در پیش‌بینی ورشکستگی، خطای نوع اول زمانی اتفاق می‌افتد که شرکت‌های طبقه غیر ورشکسته در طبقه ورشکسته طبقه‌بندی شود. خطای نوع دوم به معنی اشتباه رد فرض صفر، زمانی که آن، حالت صحیح طبیعت است. در پیش‌بینی ورشکستگی، خطای نوع دوم زمانی اتفاق می‌افتد که شرکت ورشکسته در طبقه غیرورشکسته، طبقه‌بندی شود.

به منظور ارزیابی سودمندی روش‌های انتخاب متغیر، دقت حاصل از استفاده از متغیرهای منتخب هر یک از روش‌های انتخاب متغیر با دقت پیش‌بینی حاصل از عدم انجام مرحله انتخاب متغیرهای پیش‌بین مقایسه می‌شود. منظور از عدم انجام مرحله انتخاب متغیرهای پیش‌بین، استفاده از کلیه متغیرهای پیش‌بین (۶۹ متغیر) برای پیش‌بینی بحران مالی است. همچنین، دقت حاصل از پیش‌بینی با متغیرهای منتخب هر یک از این روش‌ها با دقت حاصل از متغیرهای پیش‌بین مربوط به برخی پژوهش‌های متداول گذشته که در اغلب پژوهش‌ها استفاده می‌شود، مقایسه می‌شود. پژوهش‌های گذشته که متغیرهای مورد استفاده در آن‌ها در اغلب پژوهش‌های اخیر استفاده و در این پژوهش نیز به‌عنوان مبنایی برای مقایسه استفاده شده عبارتند از: بیور (۱۹۶۶)، آلتمن (۱۹۶۸)، زیمسکی (۱۹۸۴) و فالمر (۱۹۸۴).

#### ۴- یافته‌های پژوهش

جدول‌های ۳ الی ۵، میانگین دقت، خطای نوع اول و دوم مربوط به پیش‌بینی بحران مالی را براساس متغیرهای منتخب روش‌های مختلف انتخاب متغیر با استفاده از طبقه‌بندی‌کننده‌های شبکه‌های عصبی، ماشین بردار پشتیبان و بوستینگ نشان می‌دهد. از تحلیل واریانس برای بررسی سطح معناداری عملکرد پیش‌بینی بین شش روش انتخاب متغیر استفاده شد. در این راستا، از دقت‌های حاصل از ۱۰ بار تکرار روایی متقابل ۱۰ بخشی (روایی متقابل ۱۰ بخشی با ۱۰ بار تکرار) استفاده شد که منجر به ایجاد ۱۰۰ دقت در مورد هر طبقه‌بندی‌کننده می‌شود. با توجه به آماره  $F$  و مقدار احتمال مربوطه، به استثنای خطای نوع اول در طبقه‌بندی‌کننده شبکه‌های عصبی مصنوعی، تفاوت معناداری بین معیارهای ارزیابی عملکرد پیش‌بینی بحران مالی در هر سه طبقه‌بندی‌کننده وجود داشت. جدول ۶ نیز رتبه میانگین دقت روش‌های مختلف انتخاب متغیر را در طبقه‌بندی‌کننده‌های شبکه‌های عصبی، ماشین بردار پشتیبان و بوستینگ نشان می‌دهد.

جدول ۳- عملکرد روش‌های مختلف انتخاب متغیرها با استفاده از طبقه‌بندی کننده شبکه عصبی

عملکرد	روش انتخاب	t	رگرسیون گام به گام	تحلیل عاملی	روکشی	SVM Attribute	ریلیف	F	sig
دقت		۹۰/۰۴	۹۱/۸۱	۹۰/۰۵	۹۲/۹۱	۹۰/۰۷	۸۶/۸۴	۳/۵۴۰	۰/۰۰۴
خطای نوع اول		۰/۱۱	۰/۱۱	۰/۰۶	۰/۰۶	۰/۰۸	۰/۱۲	۰/۶۸۹	۰/۶۳۲
خطای نوع دوم		۰/۰۹	۰/۰۵	۰/۱۴	۰/۰۸	۰/۱۱	۰/۱۳	۳/۴۵۱	۰/۰۰۴

منبع: یافته‌های پژوهشگر

جدول ۴- عملکرد روش‌های مختلف انتخاب متغیرها با استفاده از ماشین بردار پشتیبان

عملکرد	روش انتخاب	t	رگرسیون گام به گام	تحلیل عاملی	روکشی	SVM Attribute	ریلیف	F	sig
دقت		۹۱/۲۳	۹۳/۵۷	۸۹/۴۷	۹۴/۸۵	۹۴/۲۱	۹۱/۰۵	۱۳/۰۹۳	۰/۰۰۰
خطای نوع اول		۰/۰۷	۰/۰۵	۰/۱۳	۰/۰۴	۰/۰۶	۰/۰۶	۱۹/۶۳۳	۰/۰۰۰
خطای نوع دوم		۰/۱۰	۰/۰۸	۰/۰۸	۰/۰۶	۰/۰۵	۰/۱۲	۱۳/۳۷۵	۰/۰۰۰

منبع: یافته‌های پژوهشگر

جدول ۵- عملکرد روش‌های مختلف انتخاب متغیرها با استفاده از طبقه‌بندی کننده بوستینگ

عملکرد	روش انتخاب	t	رگرسیون گام به گام	تحلیل عاملی	روکشی	SVM Attribute	ریلیف	F	sig
دقت		۹۰/۶۴	۹۲/۹۸	۷۹/۵۳	۹۳/۰۵	۹۱/۵۸	۹۰/۵۲	۳۳/۵۲۰	۰/۰۰۰
خطای نوع اول		۰/۰۶	۰/۰۷	۰/۱۸	۰/۰۷	۰/۰۷	۰/۰۶	۱۰/۵۲۲	۰/۰۰۰
خطای نوع دوم		۰/۱۲	۰/۰۷	۰/۲۳	۰/۰۷	۰/۰۹	۰/۱۲	۳۳/۳۲۷	۰/۰۰۰

منبع: یافته‌های پژوهشگر

جدول ۶- مقایسه و رتبه‌بندی دقت روش‌های مختلف انتخاب متغیرهای پیش‌بین

روش انتخاب متغیر	طبقه‌بندی کننده	شبکه‌های عصبی	ماشین بردار پشتیبان	بوستینگ
آزمون t	۵	۴	۴	۴
رگرسیون گام به گام	۲	۳	۳	۲
تحلیل عاملی	۴	۶	۶	۶
روکشی	۱	۱	۱	۱
SVM Attribute	۳	۲	۲	۳
ریلیف	۶	۵	۵	۵

منبع: یافته‌های پژوهشگر

جدول‌های ۷ الی ۹، میانگین دقت، خطای نوع اول و دوم مربوط به پیش‌بینی بحران مالی را بدون انجام مرحله انتخاب متغیرهای پیش‌بین (با کل ۶۹ متغیر اولیه) و همچنین با متغیرهای متداول در پژوهش‌های گذشته (مدل‌های آلتمن، بیور، زیمسکی و فالمر) با استفاده از طبقه‌بندی‌کننده‌های شبکه‌های عصبی، ماشین بردار پشتیبان و بوستینگ نشان می‌دهد. نتایج حاصل از مقایسه این جدول‌ها با جدول‌های ۳ الی ۵ حاکی از آن است که در صورت استفاده از طبقه‌بندی‌کننده‌های شبکه‌های عصبی و ماشین بردار پشتیبان، دقت حاصل از استفاده از متغیرهای منتخب روش‌های انتخاب متغیرها نسبت به عدم انجام مرحله انتخاب متغیرهای پیش‌بین (استفاده از کل متغیرها) بیشتر و خطا کمتر است. در صورت استفاده از طبقه‌بندی‌کننده بوستینگ، دقت حاصل از استفاده از متغیرهای منتخب روش‌های انتخاب متغیرها (به استثنای روش تحلیل عاملی) نسبت به عدم انجام مرحله انتخاب متغیرهای پیش‌بین (استفاده از کل متغیرها) بیشتر و خطا، کمتر است. این نتایج دال بر سودمندی روش‌های انتخاب متغیر است، زیرا علی‌رغم کاهش تعداد متغیرهای پیش‌بین، عملکرد پیش‌بینی را بهبود می‌دهند. همچنین، در اغلب موارد، متغیرهای منتخب روش‌های مورد بررسی، عملکرد بهتری نسبت به متغیرهای پژوهش‌های متداول گذشته دارد که این نتایج نیز سودمندی روش‌های انتخاب متغیر را تأیید می‌کند.

#### جدول ۷- عملکرد متغیرهای پیش‌بین بدون انجام مرحله انتخاب متغیر با استفاده از شبکه عصبی

آلتمن	بیور	زیمسکی	فالمر	کل متغیرها	
۰/۸۲	۰/۸۳	۰/۸۲	۰/۷۹	۰/۸۳	دقت
۰/۱۷	۰/۲۰	۰/۲۰	۰/۲۰	۰/۱۶	خطای نوع اول
۰/۲۰	۰/۱۴	۰/۱۵	۰/۲۱	۰/۱۸	خطای نوع دوم

منبع: یافته‌های پژوهشگر

#### جدول ۸- عملکرد متغیرهای پیش‌بین بدون انجام مرحله انتخاب متغیر با استفاده از ماشین بردار

آلتمن	بیور	زیمسکی	فالمر	کل متغیرها	
۰/۸۵	۰/۸۳	۰/۸۳	۰/۸۲	۰/۸۷	دقت
۰/۱۶	۰/۲۵	۰/۱۹	۰/۱۸	۰/۱۲	خطای نوع اول
۰/۱۵	۰/۱۰	۰/۱۵	۰/۱۹	۰/۱۱	خطای نوع دوم

منبع: یافته‌های پژوهشگر

#### جدول ۹- عملکرد متغیرهای پیش‌بین بدون انجام مرحله انتخاب متغیر با استفاده از بوستینگ

آلتمن	بیور	زیمسکی	فالمر	کل متغیرها	
۰/۸۷	۰/۷۹	۰/۸۳	۰/۸۳	۰/۸۴	دقت
۰/۰۹	۰/۲۲	۰/۲۲	۰/۱۳	۰/۱۳	خطای نوع اول
۰/۱۸	۰/۱۹	۰/۱۲	۰/۲۲	۰/۱۸	خطای نوع دوم

منبع: یافته‌های پژوهشگر

## ۵- نتیجه‌گیری و بحث

مرحله انتخاب متغیرهای پیش‌بین به عنوان یکی از مراحل است که باید قبل از پیش‌بینی استفاده شود و گامی موثر در انتخاب اطلاعات ارزشمندتر در بین اطلاعات وسیع است. به عبارت دیگر، هدف این مرحله، فیلتر کردن اطلاعات نامربوط یا اضافی است و در نتیجه می‌تواند عملکرد مدل را با کاهش تلاش برای آموزش بهبود بخشد. علی‌رغم اهمیت مرحله انتخاب متغیرهای پیش‌بین قبل از پیش‌بینی، این مرحله کمتر در ادبیات پیش‌بینی ورشکستگی و بحران مالی بررسی شده است و بیشتر مطالعات بر ایجاد مدل‌های پیش‌بینی اثربخش‌تر با قابلیت‌های پیش‌بینی بهتر، بدون توجه به انتخاب متغیرهای پیش‌بین، تأکید داشته‌اند. در این پژوهش، ۶ روش انتخاب متغیر بررسی و مقایسه شده است. این روش‌ها شامل آزمون t، تحلیل ممیزی گام به گام، تحلیل عاملی، ریلیف، مبتنی بر روکشی و مبتنی بر بردارهای پشتیبان است. افزون بر این، به منظور کسب نتایج تجربی قابل مقایسه، از سه طبقه‌بندی‌کننده شبکه‌های عصبی، ماشین بردار پشتیبان و بوستینگ استفاده شده است. به منظور مقایسه عملکرد روش‌های مختلف انتخاب متغیرهای پیش‌بین، از معیارهای میانگین دقت و خطاهای نوع اول و دوم استفاده شد.

به‌طور کلی، یافته‌های پژوهش حاکی از تأثیر مثبت استفاده از روش‌های انتخاب متغیرهای پیش‌بین (نسبت به عدم استفاده از این روش‌ها و پیش‌بینی با استفاده از ۶۹ متغیر) بر عملکرد پیش‌بینی بحران مالی است. به عبارت دیگر، در صورت استفاده از روش‌های انتخاب متغیرهای پیش‌بین، میانگین دقت افزایش و خطای نوع اول و دوم کاهش می‌یابد. دلیل برتری معیارهای عملکرد در حالت انجام مرحله انتخاب متغیرها نسبت به عدم انجام این مرحله، مسأله اضافه‌بار ابعاد می‌باشد. به نظر می‌رسد اضافه کردن متغیرهای بیشتر، پارازیت و در نتیجه خطا را افزایش می‌دهد و اضافه کردن متغیرها تا یک حد معین می‌تواند به بهبود پیش‌بینی کمک کند و اضافه کردن بیشتر متغیرها منجر به مسأله اضافه‌بار ابعاد می‌شود. افزون بر این، یافته‌های پژوهش حاکی از برتری روش مبتنی بر روکشی نسبت به سایر روش‌های انتخاب متغیر است، زیرا این روش با کاهش مناسب تعداد متغیرهای پیش‌بین، بیشترین دقت و کمترین خطای نوع اول و دوم را در هر سه طبقه‌بندی‌کننده دارا می‌باشد.

### محدودیت‌های پژوهش

علی‌رغم اهمیت نوع صنعت در پیش‌بینی بحران مالی، به دلیل حجم محدود جامعه، در انتخاب شرکت‌های سالم، امکان تطبیق شرکت‌های سالم و درمانده مالی از نظر نوع صنعت وجود نداشت. با این وجود، استفاده از صنایع مختلف در این پژوهش، باعث افزایش تعمیم‌پذیری یافته‌های پژوهش به کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران می‌شود. همچنین، علی‌رغم این که برخی از متغیرهای پیش‌بین بکار رفته در پژوهش‌های خارجی برای پیش‌بینی بحران مالی سودمند به نظر می‌رسید، به دلیل عدم امکان محاسبه این متغیرها از طریق پایگاه‌های اطلاعاتی ذکر شده در پژوهش، از محاسبه و استفاده از آن‌ها در مرحله انتخاب متغیرهای پیش‌بین و همچنین در پیش‌بینی بحران مالی صرف‌نظر شد.

با توجه به یافته‌های این پژوهش، مبنی بر تأثیر مثبت استفاده از روش‌های انتخاب متغیرهای پیش‌بین نسبت به عدم استفاده از این روش‌ها بر عملکرد پیش‌بینی بحران مالی، به افراد و مؤسسه‌های زیر پیشنهاد می‌شود که در پیش‌بینی بحران مالی، مرحله انتخاب متغیرهای پیش‌بین را انجام دهند و صرفاً بر اساس پژوهش‌های گذشته به انتخاب متغیرهای پیش‌بین مبادرت نورزند:

- ۱) حساب‌برسان به‌عنوان اعتباردهندگان به اطلاعات صورت‌های مالی شرکت‌ها در ارزیابی فرض تداوم فعالیت.
  - ۲) بانک‌ها و سایر مؤسسه‌های اعتباری در تصمیم‌گیری در مورد اعطا یا عدم اعطای اعتبار و شرایط آن و همچنین تعیین سیاست‌هایی برای نظارت بر وام‌های موجود.
  - ۳) سرمایه‌گذاران و سهامداران در تصمیم‌گیری‌های سرمایه‌گذاری مبنی بر خرید و فروش سهام، کاهش خطر سبب سرمایه‌گذاری و ارزیابی ریسک شرکت.
  - ۴) مدیران در انجام اقدام‌هایی پیشگیرانه جهت جلوگیری از ورشکستگی و مدیریت بهتر.
- افزون بر این، با توجه به قدرت بیشتر روش مبتنی بر روشی به این افراد و موسسه‌ها پیشنهاد می‌شود که در مرحله انتخاب متغیرهای پیش‌بین از این روش استفاده کنند.

#### فهرست منابع

- \* اقدامی، اسماعیل؛ کردرستمی، سهراب؛ ملکی، مجتبی؛ و آزماينده، ام‌حبیبه (۱۳۹۴). ارزیابی ورشکستگی در بورس اوراق بهادار تهران با بکارگیری مدل پویایی شبکه: روشی بر پایه تحلیل پوششی داده‌ها، مجله مهندسی مالی و مدیریت اوراق بهادار، شماره ۲۲، صص. ۱۶۵-۱۸۰.
- \* پورزمانی، زهرا؛ و کلانتری، حسن (۱۳۹۲). مقایسه قدرت پیش‌بینی بحران مالی توسط تکنیک‌های مختلف هوش مصنوعی، پژوهش‌های حسابداری مالی و حسابرسی، پژوهشنامه حسابداری مالی و حسابرسی، دوره ۵، شماره ۱۷، صص. ۳۳-۶۴.
- \* پورزمانی، زهرا؛ کی‌پور، رضا؛ و نورالدین، مصطفی (۱۳۸۹). بررسی توانمندی الگوهای پیش‌بینی کننده بحران مالی (الگوهای مورد مطالعه: الگوهای مبتنی بر روش‌های سنتی، الگوریتم ژنتیک و شبکه‌های عصبی). مجله مهندسی مالی و مدیریت اوراق بهادار، شماره ۴، صص. ۱-۲۸.
- \* راعی، رضا؛ و فلاح‌پور، سعید (۱۳۸۷). کاربرد ماشین بردار پشتیبان در پیش‌بینی درماندگی مالی شرکت‌ها با استفاده از نسبت‌های مالی، بررسی‌های حسابداری و حسابرسی، دوره ۱۵، شماره ۵۳، صص. ۱۷-۳۴.
- \* راعی، رضا؛ و فلاح‌پور، سعید (۱۳۸۳). پیش‌بینی درماندگی مالی شرکت‌ها با استفاده از شبکه‌های عصبی مصنوعی، تحقیقات مالی، شماره ۱۷، صص. ۳۹-۶۹.



- \* رهنمای رودپشتی، فریدون؛ علی‌خانی، راضیه؛ و مران‌جوری، مهدی (۱۳۸۸). بررسی کاربرد مدل‌های پیش‌بینی ورشکستگی آلتمن و فالمر در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، بررسی‌های حسابداری و حسابرسی، دوره ۱۶، شماره ۵۵، صص. ۱۹-۳۴.
- \* سعیدی، علی؛ و آقای، آرزو (۱۳۸۸). پیش‌بینی درماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از شبکه‌های بیز، بررسی‌های حسابداری و حسابرسی، دوره ۱۶، شماره ۵۶، صص. ۵۹-۷۸.
- \* عرب مازار یزدی، محمد؛ و صفرزاده، محمدحسین (۱۳۸۸). بررسی توانایی نسبت‌های مالی در پیش‌بینی بحران مالی: تحلیل لاجیت، فصلنامه بورس اوراق بهادار، سال دوم، شماره ۸، صص. ۷-۳۷.
- \* فدایی‌نژاد، محمد اسماعیل؛ و اسکندری، رسول (۱۳۹۰). طراحی و تبیین مدل پیش‌بینی ورشکستگی شرکت‌ها در بورس اوراق بهادار تهران، تحقیقات حسابداری و حسابرسی، شماره ۹، صص. ۳۸-۵۵.
- \* قالیباف‌اصل، حسن؛ و افشار، منیژه (۱۳۹۳). بررسی کاربرد استفاده از مدل KMV در پیش‌بینی ریسک ورشکستگی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران و مقایسه مدل با نتایج مدل Z رتبه آلتمن، مجله مهندسی مالی و مدیریت اوراق بهادار، شماره ۲۱، ۷۵-۸۸.
- \* کلانتری، خلیل (۱۳۸۵). پردازش و تحلیل داده‌ها در تحقیقات اجتماعی-اقتصادی. چاپ دوم، تهران، انتشارات شریف.
- \* مشایخی، بیتا؛ و گنجی، حمیدرضا (۱۳۹۳). تأثیر کیفیت سود بر پیش‌بینی ورشکستگی با استفاده از شبکه عصبی مصنوعی، پژوهش‌های حسابداری مالی و حسابرسی، سال ششم، شماره ۲۲، صص. ۱۴۷-۱۷۳.
- \* موسوی‌شیری، محمود؛ و طبرستانی، محمدرضا (۱۳۸۸). پیش‌بینی درماندگی مالی با استفاده از تحلیل پوششی داده‌ها، تحقیقات حسابداری، شماره دوم، صص. ۱۵۸-۱۸۷.
- \* مهرانی، ساسان؛ مهرانی، کاوه؛ منصفی، یاشار؛ و کرمی، غلامرضا (۱۳۸۴). بررسی کاربردی الگوهای پیش‌بینی ورشکستگی زیمسکی و شیراتا در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، بررسی‌های حسابداری و حسابرسی، سال دوازدهم، شماره ۴۱، صص. ۱۰۵-۱۳۱.
- \* منهاج، محمد باقر (۱۳۷۷). مبانی شبکه‌های عصبی، تهران، مرکز نشر پرفسور حسابی.
- \* نیکبخت، محمدرضا؛ و شریفی، مریم (۱۳۸۹). پیش‌بینی ورشکستگی مالی شرکت‌های بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی، مدیریت صنعتی، دوره ۲، شماره ۴، صص. ۱۶۳-۱۸۰.
- \* نیکومرام، هاشم؛ و پورزمانی، زهرا (۱۳۸۸). بررسی رابطه بین الگوهای پیش‌بینی بحران مالی (الگوهای مورد مطالعه: آلتمن و دیکین)، پژوهش‌های حسابداری مالی و حسابرسی، دوره ۱، شماره ۱، صص. ۳۳-۴۲.
- \* Alfaro, E., García, N., Gámez, M., and Elizondo, D. (2008). "Bankruptcy Forecasting: An Empirical Comparison of AdaBoost and Neural Networks", Decision Support Systems, Vol. 45, pp. 110-122.

- \* Altman, E. I. (1968). "Financial Ratios, Discriminant Analysis, and the Prediction of Corporate Bankruptcy", *Journal of Finance*, Vol. 23, No. 4, pp. 589-609.
- \* Atiya, A. F. (2001). "Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Results", *IEEE Transactions on Neural Networks*, Vol. 12, No. 4, pp. 929-935.
- \* Beaver, W. (1966). "Financial Ratios as Predictors of Failure." *Journal of Accounting Research*, Vol. 4, pp. 71-111.
- \* Canbas, S., Cabuk, A., and Kilic, S. B. (2005). "Prediction of Commercial Bank Failure via Multivariate Statistical Analysis of Financial Structures: The Turkish Case", *European Journal of Operational Research*, Vol. 166, pp. 528-546.
- \* Das, S. R., and Nayak, A. R. (1990). "A Survey on Bit Dimension Optimization Strategies of Microprograms", In *Proceedings of the 23rd Annual Workshop and Symposium on Microprogramming and Microarchitecture*, pp. 281-291.
- \* Deakin, E. (1972). "A Discriminant Analysis of Predictors of Business Failure", *Journal of Accounting Research*, Vol. 10, No. 1, PP. 167-179.
- \* Etemadi, H., Anvary Rostamy, A. A., and Farajzadeh Dehkordi, H. (2009). "A Genetic Programming Model for Bankruptcy Prediction: Empirical Evidence from Iran", *Expert Systems with Applications*, Vol. 36, pp. 3199 - 3207.
- \* Fernandez-Castro, A., and Smith, P. (1994). "Toward a General Nonparametric Model of Corporate Performance", *Omega: The International Journal of Management Science*, Vol. 22, No. 3, pp. 237-249.
- \* Foster, G. (1986). *Financial Statement Analysis*. New Jersey: Prentice-Hall. Inc.
- \* Fulmer, J., Moon, J., James, E., Gavin, T., Erwin, A., and Michael, J. (1984). "A Bankruptcy Classification Model for Small Firms", *Journal of Commercial Bank Lending*, Vol. 66, No. 11, pp. 25-37.
- \* Gaspar-Cunha, A., Mendes, F., Duarte, J., Vieira, A., Ribeiro, B., Ribeiro, A., and Neves, J. (2010). "Feature Selection for Bankruptcy Prediction: A Multi-Objective Optimization Approach", *International Journal of Natural Computing Research*, Vol. 1, No. 2, pp. 71-91.
- \* Guyon, I., Weston, J., Barnhill, S., and Vapnik, V. (2002). "Gene Selection for Cancer Classification Using Support Vector Machines", *Machine Learning*, Vol. 46, pp. 389-422.
- \* Hall, M. A. (2000) "Correlation-based Feature Selection for Discrete and Numeric ClassMachine Learning", In *Proceedings of the Seventeenth international Conference on Machine Learning (June 29 - July 02)*, pp. 359-366.
- \* Hu, Y. C. (2010). "Analytic Network Process for Pattern Classification Problems Using Genetic Algorithms", *Information Sciences*, Vol. 180, pp. 2528-2539.
- \* Huang, Z., Chen, H., Hsu, C. J., Chen, W. H., and Wu, S. (2004). "Credit Rating Analysis with Support Vector Machines and Neural Networks: A Market Comparative Study", *Decision Support Systems*, Vol. 37, pp. 543-558.
- \* Hung, C. and Chen, J. (2009). "A Selective Ensemble Based on Expected Probabilities for Bankruptcy Prediction", *Expert Systems with Applications*, Vol. 36, pp. 5297-5303.
- \* Jardin, P. (2010). "Predicting Bankruptcy Using Neural Networks and Other Classification Methods: The Influence of Variable Selection Techniques on Model Accuracy", *Neurocomputing*, Vol. 73, pp. 2047-2060.
- \* Kim, M. and Kang, D. (2010). "Ensemble with Neural Networks for Bankruptcy Prediction", *Expert Systems with Applications*, Vol. 37, pp. 3373-3379.
- \* Kira, K. and Rendell, L. A. (1992). "A Practical Approach to Feature Selection", *Proceedings of International Conference on Machine Learning*, pp. 249 -256.

- \* Kohavi, R., John, G. H. (1997). "Wrappers for Feature Subset Selection", *Artificial Intelligence*, Vol. 97, No. 1-2, pp. 273-324.
- \* Leano, H. J. (2004). "Discriminant Analysis, Factor Analysis and Linear Regression Analysis to Classify Financially Distressed Firms and Predict Bankruptcy Using Financial Ratios and Macroeconomic Predictors", M. A Thesis, Lamar University.
- \* Liang, D., Tsai, C. H., and Wu, H. T. (2015). "The Effect of Feature Selection on Financial Distress Prediction", *Knowledge-Based Systems*, Vol. 73, pp. 289-297.
- \* Lindenbaum, M., Markovitch, S., and Rusakov, D. (2004). "Selective Sampling for Nearest Neighbor Classifiers", *Machine Learning*, Vol. 2, pp. 125-152.
- \* Lo, S. C. (2010). "The Effects of Feature Selection and Model Selection on the Correctness of Classification", *Proceedings of the 2010 IEEE IEEM*, pp. 989-993.
- \* Min, J. H., and Lee, Y. (2005). "Bankruptcy Prediction Using Support Vector Machine with Optimal Choice of Kernel Function Parameters", *Expert Systems with Applications*, Vol. 28, pp. 603- 614.
- \* Namazi, M., and Sadeghzadeh Maharluie, M. (2015). "Detecting Earnings Management via Statistical and Neural Networks Techniques", *International Scholarly and Scientific Research & Innovation*, Vol. 9, No. 7, pp. 1192-1200.
- \* Odom, M. D., and Sharda, R. (1990). "A Neural Network Model for Bankruptcy Prediction", *IJCNN International Joint Conference on Neural Networks*, Vol. 2, pp. 163-168.
- \* Sarkar, S., and Sriram, R. S. (2001). "Bayesian Models for Early Warning of Bank Failures", *Management Science*, Vol. 47, No. 11, pp. 1457-1475.
- \* Shin, K. S., and Lee, Y. J. (2002). "A Genetic Algorithm Application in Bankruptcy Prediction Modeling", *Expert Systems with Applications*, Vol. 23, No. 3, pp. 321-328.
- \* Shin, K., and Lee, T. S., and Kim, H. (2005). "An Application of Support Vector Machines in Bankruptcy Prediction Model", *Expert Systems with Applications*, Vol. 28, pp. 127-135.
- \* Sun, J., Jia, M., and Li, H. (2011). "AdaBoost Ensemble for Financial Distress Prediction: An Empirical Comparison with Data from Chinese Listed Companies", *Expert Systems with Applications*, Vol. 38, No. 8, pp. 1- 8.
- \* Tsai, C. (2009). "Feature Selection in Bankruptcy Prediction", *Knowledge-Based Systems*, Vol. 22, pp. 120-127.
- \* Tung, W., Quek, C., Cheng, P. (2004). "Genso-ews: A Novel Neural-fuzzy Based Early Warning System for Predicting Bank Failures", *Neural Networks*, Vol. 17, pp. 567-587.
- \* Wang, G., Ma, J., and Yang, S. (2014). "An Improved Boosting Based on Feature Selection for Corporate Bankruptcy Prediction", *Expert Systems with Applications*, Vol. 41, No. 5, pp. 2353-2361.
- \* Zmijewski, M. E. (1984). "Methodological Issues Related to the Estimation of Financial Distress Prediction Models", *Journal of Accounting Research*, Vol. 22 (Supplement), pp. 59-82

## یادداشت‌ها

- <sup>1</sup> Leano
- <sup>2</sup> Lo
- <sup>3</sup> Foster
- <sup>4</sup> Etemadi
- <sup>5</sup> Atiya
- <sup>6</sup> Tung
- <sup>7</sup> Tsai
- <sup>8</sup> Shin and Lee
- <sup>9</sup> Hung
- <sup>10</sup> Canbas
- <sup>11</sup> Min
- <sup>12</sup> Gaspar- Cunha
- <sup>13</sup> Das and Nayak
- <sup>14</sup> Lindenbaum
- <sup>15</sup> Hall
- <sup>16</sup> Curse of Dimensionality
- <sup>17</sup> Filter
- <sup>18</sup> Wrapper
- <sup>19</sup> Beaver
- <sup>20</sup> Altman
- <sup>21</sup> Deakin
- <sup>22</sup> Fulmer
- <sup>23</sup> Zmijewski
- <sup>24</sup> Odom
- <sup>25</sup> Fernandez-Castro and Smith
- <sup>26</sup> Sarkar and Sriram
- <sup>27</sup> Alfaro
- <sup>28</sup> Chen
- <sup>29</sup> Kim and Kang
- <sup>30</sup> Sun
- <sup>31</sup> Jardin
- <sup>32</sup> Wang
- <sup>33</sup> Liang
- <sup>34</sup> Relief
- <sup>35</sup> Nearest Hit
- <sup>36</sup> Nearest Miss
- <sup>37</sup> Cross Validation
- <sup>38</sup> Hill-Climing
- <sup>39</sup> Best-first
- <sup>40</sup> Kohavi and John
- <sup>41</sup> Recursive Feature Elimination
- <sup>42</sup> Guyon
- <sup>43</sup> Support Vector Machine - SVM
- <sup>44</sup> Overfitting
- <sup>45</sup> AdaBoost
- <sup>46</sup> Vapnik
- <sup>47</sup> 10-fold Cross Validation
- <sup>48</sup> Hu