فصلنامه علمی پژوهشی دانش سرمایه‌گذاری
دوره ۱۵ / شماره ۳ (پیاپی ۵۹) / پائیز ۱۴۰۵
صفحه ۱۸۷ تا ۲۱۸

آزمون توان اندازه گیری تکنیکهای شبکه های عصبی و تکنیک های داده کاوی در پیش بینی درماندگی مالی

سید علی رضا روئین تن
دانشجوی دکتری، گروه مالی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران
go2s_alireza@yahoo.com

کامبیز پیکارجو
استادیار گروه اقتصاد، دانشکده مدیریت،واحد علوم و تحقیقات ، تهران، ایران(نویسنده مسئول)
k.peykarjou@srbiau.ac.ir

مریم خلیلی عراقی
استادیار گروه مدیریت مالی،دانشکده مدیریت، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران،ایران
m.khaliliaraghi@gmail.com

تاریخ دریافت: ۱۴۰۲/۰۲/۱۴ تاریخ پذیرش: ۱۴۰۲/۰۴/۰۷

چکیده

برای بهبود دقت مدل پیش‌بینی درماندگی مالی، این مقاله با کنار گذاشتن برخی قاعده مندیهای رایج در شرکت بورس اوراق بهادار - که قبلا توسط آن دسته از شرکت‌هایی که متوقف و تعلیق شدند، نقض شده است – شرکتهای نمونه را در اسکوپی جدید مورد ارزیابی قرارمیدهد. استفاده از شاخص های مالی و غیر مالی بصورت توامان، استفاده از تحلیل عاملی برای استخراج متغیرهای سازگار و استفاده از تکنیک های شبکه عصبی مصنوعی (ANN) و داده کاوی (DM) برای ساخت مدل پیش بینی درماندگی مالی از اهم موارد بنیادین ساختار تحقیق فوق بوده است. مجموعا ۳۷ شاخص در ۶۸ شرکت پذیرفته شده در بورس به عنوان نمونه اولیه، در روشها و تکنیک های مختلف به آزمون گزارده شده است.

نتایج بدست آمده نشان میدهند (۱) رویکردهای ANN و DM در تحلیل عاملی دقت کمتری بدست میدهند (۲) هرچه به وقوع واقعی درماندگی مالی نزدیک‌تر شویم، دقت بیشتری به دست می‌آوریم(دستیابی به ۸۲.۱۴ درصد صحت برای دو فصل قبل از وقوع درماندگی مالی) (۳) تحلیل عاملی، خطای طبقه‌بندی شرکت‌های درمانده در دسته شرکت‌های عادی را افزایش می‌دهد. (۴)در نهایت با توسعه مدل پیش‌بینی درماندگی مالی، دقت رویکرد ANN نسبت به رویکرد DM بیشتر است. در پایان، این مقاله استفاده از رویکرد هوش مصنوعی (AI) را در مدل مهندسی مالی،روش مناسب‌تری برای پیش‌بینی درماندگی مالی بالقوه یک شرکت میداند.

واژه‌های کلیدی: رویکرد مهندسی مالی، مدل جامع پیش‌بینی درماندگی مالی، شبکه‌های عصبی مصنوعی، داده‌کاوی.

۱- مقدمه

در ایران، بازارهای سرمایه داخلی و خارجی در سال های اخیر به سرعت توسعه یافته اند و به تدریج ایده سرمایه گذاری مالی را در اختیار مردم قرار داده است. سرمایه گذاری های مالی مختلفی مانند سهام، قراردادهای آتی، اختیار معامله، صندوق های اوراق قرضه و غیره وجود دارد و سرمایه گذاری سهام پذیرفته شده ترین حالت در جامعه است. با این حال، بازارهای سرمایه متزلزل هستند و بیشتر سرمایه گذاران تنها پس از انتشار صورت مالی شرکت می دانند که یک شرکت با درماندگی مالی مواجه است. بنابراین، پیش‌بینی درماندگی مالی شرکت‌ها نقش فزاینده‌ای در جامعه امروزی بازی می‌کند، زیرا تأثیر قابل‌توجهی بر تصمیم‌گیری‌های وام دهی و سودآوری مؤسسات مالی دارد. توانایی پیش‌بینی دقیق ورشکستگی برای متخصصان مختلف، مانند مسئولین وام‌های بانکی، بستانکاران، سهامداران، دارندگان اوراق قرضه، تحلیلگران مالی، مقامات دولتی و همچنین عموم مردم از اهمیت حیاتی برخوردار است، زیرا به آنها هشدارهای به موقع ارائه می‌کند (کو و لین[1]، ۲۰۰۶). از سوی دیگر در تحقیقات نوین، از منظر رویکردهای مختلف به این مقوله توجه شده است. صرفا بعنوان یک نمونه رهنمای رودپشتی در نظریه بدیع خود در اندازه گیری ریسکهای مالی و یا غیر از آن با ارائه نظریه خویش، فضایی را فراهم آورده است تا با جامع نگری و نیز در نظر گرفتن حاکمیت پارادایم اقتضایی، امکان سنجش شاخص های مالی و غیر از آن به شکل موردی و یا جامع ، فراهم آید. در دیدگاه سنتی ، با رویکرد نقدینگی ، فعالیت ، سودآوری و اهرمی به تحلیل و اندازه گیری شاخص های مالی پرداخته میشود. (رهنمای رودپشتی، ۲۰۱۵) در دیدگاه فراسنتی ، دیدگاه مبتنی بر بازار و نیز دیدگاه مبتنی بر ارزش آفرینی مورد نظر است(نایدو، ۲۰۰۷). در دیدگاه مهندسی مالی با در نظر گرفتن مدیریت ترازنامه (نسبتهای مالی) ، مدیریت منابع و مصارف ، مهندسی پوشش ریسک و دیگر شاخصه های کلان مدیریت از جمله اقتصاد کلان ، حاکمیت شرکتی و نیز عوامل رفتاری به ارزیابی شاخص های مالی پرداخته میشود (رهنمای رودپشتی،۱۳۹۹)

اما تقریبا همگی متفق هستند که ورشکستگی مالی زمانی اتفاق می‌افتد که یک شرکت متحمل زیان‌های مزمن و جدی می‌شود یا زمانی که شرکت با بدهی‌های نامتناسب با دارایی‌هایش ورشکسته می‌شود (هوآ، وانگ، ژو، ژانگ، و لیانگ[2]، ۲۰۰۷). علل و نشانه های رایج ورشکستگی مالی عبارتند از فقدان دانش مالی، عدم تنظیم برنامه های سرمایه گذاری، مدیریت ضعیف وام دهی، عدم وجود برنامه های پیشگیرانه کافی در برابر رویدادهای پیش بینی نشده و وجود مشکلات در نظم عملیاتی مناسب در بازار مالی. معمولا فرض بر این است که هرگاه صورت‌های مالی یک شرکت به‌طور مناسب ویژگی‌های فوق را منعکس کند می توان ورشکستگی را پیش‌بینی کرد. چندین تکنیک طبقه‌بندی برای پیش‌بینی درماندگی مالی با استفاده از ضرایب و داده‌های حاصل از این صورت‌های مالی پیشنهاد شده‌اند، به‌عنوان مثال، رویکردهای تک متغیره (بیور[3]، ۱۹۶۶)، رویکردهای چند متغیره، رویکردهای متمایز چندگانه خطی (MDA) (آلتمن، ۱۹۶۸؛ آلتمن، ادوارد، هالدمن و نارایانان[4]، ۱۹۷۷)، رگرسیون

[1] Ko & Lin, 2006
2 Hua, Wang, Xu, Zhang, & Liang, 2007
3 Beaver, 1966
4 Altman, 1968; Altman, Edward,Haldeman, & Narayanan, 1977

چندگانه (مایر و پایفر[1]، ۱۹۷۰)، رگرسیون لجستیک (دیمیتراس، زناکیس، و زوپونیدیس[2]، ۱۹۹۶)، تحلیل عاملی (بلوم[3]، ۱۹۷۴)، و گام به گام (لایتینن و لاتینن[4]، ۲۰۰۰). با این حال، مفروضات دقیق آمار سنتی مانند خطی بودن، نرمال بودن، استقلال در بین متغیرهای پیش بینی کننده و فرم از پیش تعیین شده عملکردی مربوط به متغیر معیار و متغیر پیش بینی، کاربرد آنها را در دنیای واقعی محدود می کند (هوآ و دیگران[5]، ۲۰۰۷).

چالشهای نظری در این حوزه همچنان در تحقیقات مدرن پابرجاست:در مطالعه ای که از ۴۶۲۶۷۸ مشاهدات ماهانه شرکت‌های فهرست شده در ایالات متحده برای دوره ۱۹۹۰-۲۰۱۸ برای مستندسازی استفاده می کند، رابطه مثبت قوی بین تغییرات کوتاه مدت ریسک درماندگی مالی و قیمت آتی سهام را بررسی کرده است. متغیر در هر ماه احتمال سقوط قیمت سهام را ۸.۳۳ درصد نسبت به میانگین آن افزایش می دهد. این مطالعه تجزیه و تحلیل هایی را انجام می دهد که نشان می دهد رابطه درماندگی-ریسک تصادف ناشی از فرصت طلبیمدیریتی است که به دنبال پنهان کردن اخبار بد است.(اندرو،۲۰۲۰)

لی و همکاران (۲۰۲۰) طی پژوهشی با عنوان (درماندگی مالی، کنترل داخلی، و مدیریت سود: شواهدی از چین) نشان دادند که شرکتهایی که دستخوش درماندگی مالی شدند بیشتر مدیریت سود تعهدی را دنبال میکنند و کمتر بدنبال مدیریت سود واقعی هستند. لو و کائو (۲۰۱۹)در تحقیقی به بررسی رابطه میان ویژگیهای هیئت مدیره و ضعف کنترل داخلی پرداختند. نتایج نشان می دهد که ویژگیهای فردی اعضای هیئت مدیره شامل تجربه، صدور گواهینامه و آموزش با نقص در کنترل داخلی مرتبط میباشد. هم چنین، در شرکتهایی که اعضای هیئت مدیره دارای مدارک بالاتری هستند، کیفیت کنترل داخلی بهتر بوده، ضعفهای کنترل داخلی کاهش یافته و احتمال اصلاح ضعف بیشتر میشود. علاوه بر این، ساختارمالکیت تأثیر معناداری بر رابطه بین ویژگی های هیئت مدیره و کنترل داخلی دارد. با این حال، رفتار هیئت مدیره رابطه بین اعضای هیئت مدیره و کنترل داخلی را تعدیل نمی کند. یانگ و روت (۲۰۱۹)پژوهشی را با عنوان (عدم اطمینان سیاست و مدیریت سود) مورد بررسی قرار دادند. آنها به این نتیجه رسیدند که عدم اطمینان سیاست با مدیریت سود در ارتباط است. زمانی که عدم اطمینان سیاست زیاد (کم) است، مدیریت سود شرکتها افزایش (کاهش) مییابند. هاگا و همکاران (۲۰۱۸)طی پژوهشی با عنوان (وضعیت پذیرش در بازار سهام و مدیریت سود واقعی) نیز نشان میدهند که شرکتهای ریسکی تر همچنان از مدیریت تعهدی سودها بهره میبرند.

با تغییرات اساسی در امور مالی شرکت ها و محیط اقتصادی جهانی، ضرایب مالی بحرانی می توانند به صورت پویا تغییر کنند (جان و رابرت[6]، ۲۰۰۱). از سوی دیگر کاربست فن آوریهای دیجیتال در کانسپت مالی و بویژه بلاک چین ، تغییرات قابل توجهی را در ارائه مدلهای پیش بینی درماندگی مالی بوجود خواهد آورد. بعنوان یک نمونه عملی، پری ماندیری، در تحقیق خود به این مساله پرداخته است(پری ماندری،۲۰۲۱) :

1Meyer & Pifer,1970
2 Dimitras, Zanakis, & Zopounidis, 1996
3 Blum, 1974
4 Laitinen & Laitinen,2000
5 Hua et al., 2007
6 John & Robert, 2001

دولت منطقه ای اندونزی هنوز از روش گزارشگری مالیمرسوم با ارائه دستی برخی اسناد استفاده می کند. در نتیجه، هیچ پایگاه داده دیجیتالی ارائه نشده است. فناوری پیشنهادی ما زنجیره بلوکی است که برای گزارش‌های مالی فناوری توزیع شده پیاده‌سازی می‌شود که البته شفافیت و محرمانه بودن آن حفظ می‌شود. این تحقیق با استفاده از برنامه نویسی پایتون نمای کلی گزارش را ارائه می دهد و در پایان نتیجه میگیرد که در پیش‌بینی درماندگی مالی با استفاده از ماشین بردار پشتیبان (SVM) با تابع پایه شعاعی (RBF) دقت ۱۰۰٪ افزایش می یابد. این بدان معنی است که توسعه یک رویکرد تکاملی برای مقابله با محیط های مالی پویا در آینده مهم و ضروری است.

در مقاله جالبی ، سیدحسام واقفی و همکاران ایشان(۱۴۰۱)، به بررسی مقالات بازه زمانی ۱۳۸۲ تا ۱۳۹۹ پرداختند که یافته های تحقیق نشان می دهد که در۴۷ ٪مقالات موضوع درماندگی مالی به عنوان متغیر مستقل و ۳۲ ٪به عنوان متغیر وابسته و ۵۸ ٪به عنوان متغیر میانجی مورد استفاده قرار میگیرد. همچنین حدود ۴۰ ٪این مقالات در مجلات حوزه حسابداری به چاپ رسیده اند. ۱۲ ٪ مقالات درماندگی مالی در حوزه مدیریت مالی و ۱۰ ٪آنها در حوزه مالی به چاپ رسیده اند و اینگونه نتیجه گرفته است که بطور کلی می توان بیان کرد که پژوهشگران ایرانی علاقه زیادی جهت تحقیق پیرامون درماندگی مالی دارند و همچنین می توان عنوان کرد که در پژوهش های بررسی شده درماندگی مالی در حوزه حسابداری، حسابرسی و مالی مورد بحث قرار گرفته است که این موضوع نشان از اهمیت حفظ سرمایه سرمایه گذاران می باشد. (واقفی،۱۴۰۱)

این مقاله مدلی از پیش‌بینی درماندگی مالی را با یکپارچه‌سازی تکنیک‌های شبکه عصبی مصنوعی (ANN) و داده‌کاوی (DM) پیشنهاد می‌کند. اهداف اصلی این مقاله عبارتند از: (۱) اتخاذ تکنیک‌های ANN و DM برای ساخت یک مدل پیش‌بینی درماندگی مالی، (۲) استفاده از ضرایب مالی و غیر مالی برای افزایش دقت مدل پیش‌بینی درماندگی مالی، (۳) استفاده از یک مدل روش آماری سنتی (تحلیل عاملی) برای مقایسه درجه دقت با رویکرد هوش مصنوعی (AI) و (۴) گسترش این مدل به طوری که در یک سیستم پیش‌بینی درماندگی مالی برای ارائه اطلاعات به سرمایه‌گذاران نیز کار کند. به عنوان سازمان های نظارت بر سرمایه گذاری، داده های تحقیق ما از پایگاه داده شرکت بورس اوراق بهادار جمع آوری شد.

بقیه این مقاله به شرح زیر تنظیم شده است. مروری بر ادبیات مطالعات مرتبط در بخش ۲، بخش ۳ رویکرد پیشنهادی ما و عملکردهای هر فرآیند را شرح می دهد. بخش ۴ فرآیند انتخاب شاخص های مناسب با تحلیل عاملی را ارائه می دهد. برای اثبات عملکرد پیش‌بینی رویکردمان، آزمایش‌های متعددی را انجام دادیم که در بخش ۵ توضیح داده شده‌اند. در بخش ۶، نتایج خود را با رویکردهای ANN و DM مقایسه کردیم. در نهایت، در بخش ۷ ما نتایج حاصل را در مورد پیش‌بینی درماندگی مالی بیان و در مورد کارهای آینده بحث می‌کنیم.

مبانی نظری و تدوین فرضیه های تحقیق

شبکه های عصبی مصنوعی

ANN از گره های غیرخطی به هم پیوسته و غنی تشکیل شده است که به صورت موازی با هم ارتباط برقرار می کنند. وزن‌های اتصال قابل تغییر هستند و به ANN اجازه می‌دهند تا مستقیماً از نمونه ها بدون نیاز به ارائه راه‌حل تحلیلی برای مشکل یاد بگیرند. محبوب ترین شکل های یادگیری عبارتند از:

- یادگیری نظارت شده: الگوهایی که هم ورودی و هم خروجی آنها شناخته شده است به ANN ارائه می شود. وظیفه یادگیرنده تحت نظارت، پیش بینی مقدار تابع برای هر شی ورودی معتبر پس از مشاهده تعدادی نمونه آموزشی است. ANN با استفاده از یادگیری نظارت شده به طور گسترده برای حل مشکلات تقریب تابع و طبقه بندی استفاده شده است.
- یادگیری بدون نظارت: الگوها در قالب مقادیر ویژگی به شبکه عصبی مصنوعی ارائه می شوند. با این واقعیت که خروجی پیشینی وجود ندارد از یادگیری تحت نظارت متمایز می شود. ANN با استفاده از یادگیری بدون نظارت با موفقیت برای داده کاوی و وظایف طبقه بندی به کار گرفته شده است. نقشه خودسازماندهی (SOM) و تئوری تشدید تطبیقی (ART) محبوب ترین نمونه این کلاس را تشکیل می دهد.

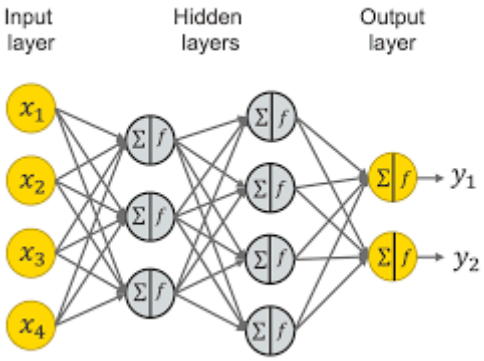

شکل ۱. ساختار شبکه (لایه ورودی، لایه پنهان، لایه خروجی)

یک شبکه پس انتشار (BPN) یک شبکه عصبی است که از روش یادگیری نظارت شده و معماری پیش‌خور استفاده می‌کند. BPN یکی از متداول‌ترین تکنیک‌های شبکه عصبی برای طبقه‌بندی و پیش‌بینی است (وو، یانگ و لیانگ[1]، ۲۰۰۶) ، و به عنوان یک تحلیل رگرسیون چندگانه پیشرفته در نظر گرفته می‌شود که می‌تواند روابط داده‌های پیچیده و غیرخطی را در خود جای دهد (جاست[2]، ۱۹۹۳). اولین بار توسط وربوس[3](۱۹۷۴) توصیف شد و توسط

1 Wu, Yang, & Liang, 2006
2 Jost,1993
3 Werbos (1974)

رونالد، راملهارت و هینتون [1](۱۹۸۶) بیشتر توسعه یافت. جزئیات الگوریتم یادگیری پس انتشار را می توان در مدسکر و لیبوویتز [2] (۱۹۹۴) یافت.

شکل ۱ معماری l- m- n (l نشان دهنده نورون های ورودی، m نشان دهنده نورون های پنهان و n نشان دهنده نورون های خروجی) یک مدل BPN را نشان می دهد (پاندا، چاکرابورتی و پال[3]، ۲۰۰۷). لایه ورودی را می توان محرک مدل و لایه خروجی را نتیجه محرک ورودی در نظر گرفت. لایه پنهان روابط نقشه برداری بین لایه های ورودی و خروجی را تعیین می کند، در حالی که روابط بین نورون ها به عنوان وزن پیوندهای اتصال، ذخیره می شود. سیگنال‌های ورودی توسط وزن اتصال، معروف به ضریب وزن wji، اصلاح می‌شوند که نشان‌دهنده اتصال گره ith لایه اول به گره jامین لایه دوم است. سپس مجموع سیگنال های اصلاح شده (فعال سازی کل) توسط یک تابع انتقال سیگموئید (f) اصلاح می شود. به طور مشابه، سیگنال‌های خروجی لایه پنهان با وزن اتصال wkj از گره kام لایه خروجی به گره j امین لایه پنهان اصلاح می‌شوند. سپس مجموع سیگنال های اصلاح شده توسط تابع انتقال سیگموئید (f) اصلاح می شود و خروجی در لایه خروجی جمع آوری می شود.

Ip = (Ip1, Ip2. . . Ipl)، p = 1,2, . . . ، N الگوی pام در بین N الگوهای ورودی است. جایی که wji و wkj به ترتیب وزن های اتصال بین نورون ورودی i به نورون پنهان j و نورون پنهان jامین به نورون خروجی k ام هستند (پاندا و دیگران[4]، ۲۰۰۷).

خروجی از یک نورون در لایه ورودی به این شرح است :

$$O_{pi} = I_{pi}, \quad i = 1,2,\ldots,l$$

خروجی از یک نورون در لایه پنهان به این شرح است :

$$O_{pj} = f(NET_{pj}) = f\left(\sum_{i=0}^{1} w_{ji} o_{pi}\right), \quad j = 1,2,\ldots,m$$

خروجی از یک نورون در لایه خروجی به این شرح است:

$$O_{pk} = f(NET_{pk}) = f\left(\sum_{j=0}^{m} w_{kj} o_{pj}\right), \quad k = 1,2,\ldots,n$$

f( ) تابع انتقال سیگموئیدی است که با این فرمول (f(x) = 1/(1 + e^(-x)) محاسبه می شود. BPN در زمینه‌های مختلفی مانند بررسی پیش‌بینی‌های جزر و مدی بلندمدت (لی[5]، ۲۰۰۴) ، بهبود رضایت مشتری (دنگ، چن، و پی[6]، ۲۰۰۷) ، پیش‌بینی ساییدگی لبه در مته‌ها (پاندا و دیگران[7]، ۲۰۰۷) افزایش پیش‌بینی زمان تکمیل کار در

1 Ronald, Rumelhart, and Hinton (1986)
2 Medsker and Liebowitz (1994)
3 (Panda, Chakraborty, & Pal, 2007)
4 Panda et al., 2007
5 Lee, 2004
6 Deng, Chen, & Pei, 2007
7 Panda et al., 2007

کارخانه ساخت نیمه‌رسانا (چن[1]، ۲۰۰۷) ، و ارائه دقت مورد نیاز برای تشخیص آریتمی‌های بطنی کانونی (ییلماز و کاندی اوغلو[2]، ۲۰۰۷) استفاده شده است.

بر اساس متون فوق، بسیاری از تحقیقات انجام شده از تکنیک های BPN برای بسیاری از کاربردها استفاده کردند. با این حال، تعداد کمی از آنها از آن برای انجام تحقیقات تجربی موضوعات مرتبط با پیش‌بینی درماندگی مالی استفاده کردند. بنابراین، در این مطالعه از تکنیک BPN برای پیش‌بینی یک بحران بالقوه در حوزه پیش‌بینی ورشکستگی استفاده خواهیم کرد. ما امیدواریم که نتایج رویکرد پیشنهادی ما روش‌شناسی مفیدی را برای سرمایه‌گذاران و همچنین سازمان‌های نظارتی برای پیش‌بینی و اجتناب از سرمایه‌گذاری در شرکتی که در آینده نزدیک در معرض ورشکستگی قرار دارد، ارائه دهد.

۲-۲. داده کاوی

داده کاوی (DM)، همچنین به عنوان "کشف دانش در پایگاه های داده" (KDD) شناخته می شود که یک فرآیند کشف الگوهای معنی دار در پایگاه های عظیم داده است (هان و کامبر[3]، ۲۰۰۱). علاوه بر این، برنامه ای است که می تواند مزایای رقابتی قابل توجهی را برای تصمیم گیری درست فراهم کند. (هوانگ، چن و لی[4]، ۲۰۰۷). DM یک فرآیند اکتشافی و پیچیده است که شامل چندین مرحله تکراری است. شکل ۲ نمای کلی از فرآیند داده کاوی را نشان می دهد (هان و کامبر[5]، ۲۰۰۱). این فرایند تعاملی و تکراری است و شامل مراحل زیر است:

- مرحله ۱. شناسایی دامنه برنامه: دامنه برنامه و دانش قبلی مربوطه را بررسی و درک کنید. علاوه بر این، هدف KDD را از دیدگاه مدیران یا کاربران شناسایی کنید.
- مرحله ۲. انتخاب مجموعه داده هدف: یک مجموعه داده مناسب را انتخاب کنید یا روی زیرمجموعه ای از متغیرها یا نمونه های داده تمرکز کنید که در آن داده های مربوط به کار تجزیه و تحلیل، از پایگاه داده بازیابی می شوند.
- مرحله ۳. پیش پردازش داده: عملیات اساسی DM شامل "پاک کردن داده" و "کاهش داده" است: در فرآیند "پاک کردن داده ها"، داده های نویز را حذف می کنیم یا به فیلد داده از دست رفته پاسخ می دهیم. در فرآیند «کاهش داده‌ها»، ابعاد غیرضروری را کاهش می‌دهیم یا روش‌های تبدیل مفیدی را اتخاذ می‌کنیم. هدف اصلی بهبود تعداد موثر متغیرهای مورد بررسی است.
- مرحله ۴. داده کاوی: این یک فرآیند ضروری است، که در آن روش های هوش مصنوعی به منظور جستجوی الگوهای معنادار یا دلخواه در یک فرم نمایشی خاص، مانند انجمن استخراج قوانین، درختان طبقه بندی، و تکنیک های خوشه بندی استفاده می شود.

1 Chen, 2007
2 Yılmaz & Cunedioglu, 2007)
3 Han & Kamber, 2001
4 Huang, Chen, & Lee, 2007
5 Han & Kamber, 2001

- مرحله ۵. استخراج دانش: بر اساس مراحل بالا می توان الگوهای استخراج شده را تجسم کرد یا بسته به مدل های استخراج، داده ها را تجسم کرد. علاوه بر این، این فرآیند همچنین هرگونه تعارض بالقوه با دانش قبلی را بررسی یا حل می کند.
- مرحله ۶. کاربرد دانش: در اینجا، دانش یافت شده را مستقیماً در دامنه برنامه فعلی یا در زمینه های دیگر برای اقدامات بیشتر اعمال می کنیم.
- مرحله ۷. ارزیابی دانش: در اینجا، جالب‌ترین الگوها را شناسایی می‌کنیم که داده‌های مبتنی بر دانش را بر اساس معیارهای مورد علاقه نشان می‌دهند. علاوه بر این، به ما امکان می دهد تا دقت و کارایی دانش استخراج شده را بهبود بخشیم.

یک الگوریتم داده کاوی خاص معمولا نمونه ای از اجزای جستجوی ترجیحی مدل است. توابع مدل رایج تر در فرآیند داده کاوی فعلی شامل موارد زیر است (میترا، پال و میترا،[1] ۲۰۰۲).

- طبقه بندی: یک آیتم داده را به یکی از چندین دسته از پیش تعریف شده طبقه بندی می کند.
- رگرسیون: یک آیتم داده را به یک متغیر پیش بینی با ارزش واقعی ترسیم می کند.
- خوشه‌بندی: یک آیتم داده را به یک خوشه ترسیم می‌کند، که در آن خوشه‌ها گروه‌بندی طبیعی از اقلام داده بر اساس معیارهای شباهت یا مدل‌های چگالی احتمال هستند.
- قاعده گذاری تجمعی: رابطه ارتباط بین صفات مختلف را توصیف می کند.
- خلاصه سازی: یک توصیف فشرده برای زیرمجموعه ای از داده ها ارائه می دهد.
- مدل‌سازی وابستگی: وابستگی‌های مهم بین متغیرها را توصیف می‌کند.
- تحلیل توالی: الگوهای متوالی را مانند تحلیل سری های زمانی شکل می دهد. هدف آن مدل سازی وضعیت فرآیند تولید توالی یا استخراج و گزارش انحرافات و روندها در طول زمان است.

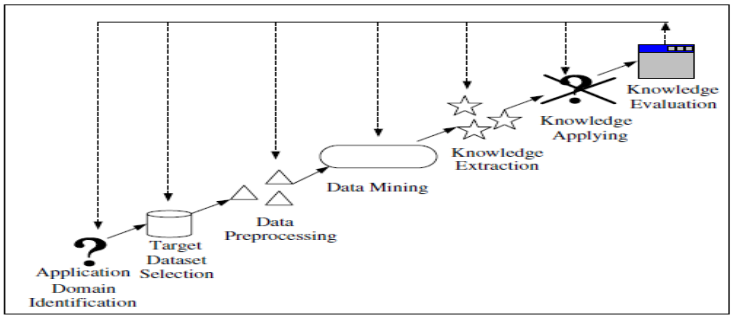

شکل ۲. مراحل داده کاوی (هان و کامبر، ۲۰۰۱)ارزیابی دانش، کاربرد دانش، استخراج دانش ، داده کاوی ، پیش پردازش داده ها ، انتخاب مجموعه داده هدف، شناسایی دامنه برنامه

1 Mitra, Pal, & Mitra, 2002

اخیرا، بسیاری از تحقیقات از تکنیک‌های داده کاوی در کار خود استفاده کرده اند. DM با موفقیت در چندین حوزه درماندگی مالی اعمال شده است. نمونه های اخیر به شرح زیر است. هوانگ، هسو و وانگ[1] (۲۰۰۷) رویکرد استخراج سری زمانی را برای شبیه سازی هوش انسانی و کشف الگوهای پایگاه داده مالی به طور خودکار اتخاذ کردند (هوانگ و همکاران[2]، ۲۰۰۷). کرکوس، اسپاتیس و مانولوپولوس[3] (۲۰۰۷) از استخراج طبقه بندی شده برای شناسایی صورت های مالی جعلی استفاده کردند (کرکوس و همکاران[4]، ۲۰۰۷). چون و پارک[5] (۲۰۰۶) تحلیل رگرسیون و استدلال مبتنی بر مورد را برای پیش‌بینی شاخص بازار سهام تکمیل کردند (چون و پارک[6]، ۲۰۰۶). با این حال، تعداد کمی از این مطالعات بر رویکرد خوشه‌بندی داده‌ها متمرکز شده‌اند، و حتی تحقیقات تجربی کمتری در مورد موضوعات مرتبط با پیش‌بینی درماندگی مالی انجام شده است. بنابراین، ما از خوشه‌بندی داده‌ها برای افزایش دقت پیش‌بینی ورشکستگی در بازار سرمایه استفاده خواهیم کرد.

با عنایت به تحقیقات صورت گرفته قبلی ، مفروضات ذیل مورد نظر قرار گرفت :

فرضیه اول: دقت رویکرد ANN نسبت به رویکرد DM بیشتر است

فرضیه دوم: نزدیک تر شدن به موقعیت درماندگی مالی، دقت روشها را افزایش میدهد.

فرضیه سوم: تحلیل عاملی، خطای قرارگرفتن شرکت‌های درمانده در دسته شرکت‌های عادی را افزایش می‌دهد.

پیشینه پژوهش

در خصوص درماندگی مالی تاکنون تحقیقات گسترده ای در داخل و خارج کشور انجام پذیرفته است :

وارد (۱۹۹۲) و وارد فاستر (۱۹۹۶ و ۱۹۹۷)، توانایی جریانات نقد را در پیش بینی درماندگی مالی شرکتها شامل نکول وام و کاهش سود تقسیمی را بررسی کرده و پی بردند که شرکت های درمانده مالی نسبت به شرکت های سالم، دو سال قبل از وقوع درماندگی، دارای خالص جریان نقد عملیاتی منفی و خالص جریان نقد سرمایه گذاری مثبت می باشند. به عبارتی، شرکت های درمانده برای کسب وجوه نقد اضافی اقدام به فروش داراییها و سایر سرمایه گذاری ها می کنند. وارد (۱۹۹۴) نشان داد که شرکت های صنعتی دو سال قبل از رویداد درماندگی دارای خالص جریان نقد تامین مالی مثبت می باشند چرا که برای کاهش مشکلات خود، تامین مالی خارجی زیادی انجام می دهند.

پیناندو و همکاران (۲۰۰۸) مجموعه ای از شرکتهای آمریکایی و گروه ۷ را انتخاب و از دو معیار کاهش دو سال متوالی در ارزش بازار و فزونی دو سال متوالی هزینه های مالی بر سودآوری شرکت جهت تفکیک شرکتها به درمانده و سالم استفاده نمودند. استفاده از رگرسیون لوجستیک در تحقیق آنان نشان می دهد که نسبتهای مالی توانایی پیش بینی درماندگی مالی را دارند.

1 Huang, Hsu, and Wang (2007)
2 Huang et al., 2007
3 Kirkos, Spathis, and Manolopoulos (2007)
4 (Kirkos et al., 2007)
5 (Chun & Park, 2006)
6 (Chun & Park, 2006)

گارسیا لارا و همکاران (۲۰۰۹) کیفیت سود در شرکت های ورشکسته را مورد بررسی قرار دادند و آن را با شرکت غیر ورشکسته مقایسه کردند. نتایج حاکی از آن است که شرکت های ورشکسته در چهار سال قبل از ورشکستگی با استفاده از دو ابزار دستکاری اقلام تعهدی و دستکاری فعالیتهای واقعی سودهای خود را به شکل افزایشی مدیریت می کنند.

لیو و هوانگ (۲۰۱۰) با انتخاب نمونه ای متشکل از ۶۸۸ شرکت تایوانی و استفاده از نسبتهای مالی و بکارگیری روش های متنوع هوش مصنوعی در بازه زمانی ۲۰۰۷-۲۰۰۰، به این رسیدند که روش ترکیبی الگریتم ژنتیک و آدابوست بالاترین توان پیش بینی داشته است.

سان و همکاران (۲۰۱۱) با مطالعه شرکتهای چینی، شرکتهایی را به عنوان درمانده مالی معرفی کردند که دو سال متوالی دارای زیان بوده و یا ارزش دفتری هر سهم آنها کمتر از ارزش اسمی هر سهم باشد. این محققین با بکارگیری نسبتهای مالی به عنوان متغیرهای پیش بین و استفاده از روشهای انفرادی و ترکیبی هوش مصنوعی به این نتیجه رسیدند که روشهای ترکیبی هوش مصنوعی بهتر از روشهای انفرادی می توانند درماندگی مالی را پیش بینی نمایند.

تینگ و لین (۲۰۱۱)، با درنظر گرفتن ۵۸ نسبت مالی و مراحل چرخه تجاری اقدام به پیش بینی ورشکستگی با روشهای رگرسیون لوجستیک، ماشین بردار پشتیبان و شبکه عصبی مصنوعی نمودند. نتایج تحقیق ایشان حاکی از توانایی بالای ماشین بردار پشتیبان در پیش بینی ورشکستگی است.

لیزانو و همکاران (۲۰۱۱)، با بررسی اثر چرخه تجاری بر پایداری مدلهای پیش بینی ورشکستگی دریافتند که ساختار مدلهای پیش بینی ورشکستگی در موقعیت های چرخه تجاری متفاوت است.

رویهائو (۲۰۱۲) از ۳ متغیر " کیفیت اقلام تعهدی" ، " قدر مطلق اقلام تعهدی غیر عادی" و "نوسانات سود" به عنوان نماینده شاخصهای کیفیت سود در پیش بینی درماندگی مالی استفاده نموده و با استفاده از رگرسیون لوجستیک نشان داد که کیفیت سود می تواند پیش بینی درماندگی مالی را تحت تاثیر قرار دهد.

آلیفیا (۲۰۱۳) با استفاده از نسبتهای مالی و متغیرهای اقتصاد کلان و بکارگیری روش رگرسیون بوجستیک در شرکتهای عضو بورس اوراق بهادار مالزی توانست به مدلی از پیش بینی درماندگی مالی دست یابدکه در این مدل، ۵متغیر نسبت بدهی، نسبت به گردش کل داراییها، نسبت سرمایه در گردش، نسبت سود خالص به کل داراییها و نرخ پایه احاره بیشتریت تاثیر را بر درماندگی مالی داشتند.

زوهرا و همکاران (۲۰۱۵) اقدام به شناسایی شرکتهای درمانده ۲۸ صنعت در اردن نموده و سه سال زیان متوالی را به عنوان ملاک تفکیک درنظر گرفتند. استفاده از ۲۷ نسبت مالی و روش آماری رگرسیون لوجستیک جهت پیش بینی درماندگی مالی نشان می دهد که مدل نهایی می تواند در سال درماندگی تا ۸۹/۳٪ قدرت پیش بینی داشته باشد. این توان در یک، دو و سه سال قبل از درماندکی به ترتیب ۶۷/۹٪ ، ۷۸/۶٪ و ۷۴/۱٪ بوده است.

لی و همکاران (۲۰۱۵) با اضافه نمودن متغیرهای اقتصاد کلان و حاکمیت شرکتی به مجموعه نسبتهای مالی به این نتیجه رسیدند که اضافه کردن این متغیرها توانایی مدلهای پیش بینی درماندگی مالی را افزایش می دهد.

لیائو و مهدیان (۲۰۱۶) با استفاده از نسبتهای مالی و معرفی یک شاخص ورشکستگی مرکب، اقدام به تبیین درجه درماندگی مالی شرکتها به صورت عددی بین و صفر و یک نمودند. در این مطالعه به منظور مقایسه کارایی شاخص معرفی شده، آن را با شاخص Z آلتمن مقایسه و نتیجه گرفته اند که قدرت پیش بینی شاخص آنها تا حدودی بهتر از شاخص آلتمن است.

جمیل و القزیری (۲۰۱۶) با بررسی ۳۷ شرکت درمانده مالی در بورس اوراق بهادار مصر به روش شبکه عصبی مصنوعی دریافتند بهترین توضیح برای پیش بینی درماندگی مالی این است که در مصر شرکتی درمانده مالی خواهد شد که با کاهش در نقدینگی، کاهش در جریانات نقدی حاصل از فروش و افزایش در اهرم مالی مواجه باشد.

لیو و وانگ (۲۰۱۶) با بررسی شرکتهای چینی مابین سالهای ۲۰۰۳ تا ۲۰۱۳ به روش رگرسیون لوجستیک دریافتند که نسبتهای بدهی (یک فصل قبل از درماندگی) و ارزش افزوده اقتصادی تعدیل نشده (دو،سه و چهار فصل قبل از درماندگی) در پیش بینی درماندگی مالی شرکتهای چینی دارای برتری هستند.

راعی و فلاحی پور (۱۳۸۳) با استفاده از نسبتهای مالی و تفکیک شرکتها براساس ماده ۱۴۱ قانون تحارت، اقدام به پیش بینی درماندگی مالی شرکتهای تولیدی، با استفاده از شبکه های عصبی مصنوعی کردند. آن ها از مدل تحلیل تشخیصی چندگانه به عنوان مدل مقایسه ای در تحقیق خود استفاده کرده اند. نتایج مدل ها نشان داد، مدل شبکه عصبی مصنوعی در پیش بینی درماندگی مالی، به طور معناداری نسبت به تحلیل تشخیصی چندگانه از دقت پیش بینی بیشتری برخوردار است.

جبارزاده و همکاران (۱۳۸۸) با بررسی اطلاعات ۸۱ شرکت مشمول ماده ۱۴۱ قانون تجارت به عنوان درمانده مالی به مطالعه ارتباط بین هموارسازی سود و درماندگی مالی پرداختند و نتیجه کرفتند مدیران برای بهتر نشان دادن وضعیت مالی و حفظ شرکت در بازار سرمایه ، اقدام به هموارسازی سود در مراحل مختلف درماندگی مالی می کنند.

اعتمادی و همکاران (۲۰۰۹) با بکارگیری مدل برنامه ریزی ژنتیک به پیش بینی ورشکستگی شرکتهای ایرانی پرداختند. مدل پیش بینی مزبور سپس با نتایج مدل تحلیل ممیزی چندگانه مقایسه شده است. جامعه آماری شامل شرکتهای بورس اوراق بهادار تهران و نمونه مورد استفاده شامل ۱۴۴ شرکت ورشکسته و سالم بوده است. نتایج این تحقیق نشان می دهد درحالی که صحت پیش بینی مدل تحلیل ممیزی، ۷۷٪ بوده، صحت پیش بینی مدل ژنیم ۹۴٪ می باشد.

مخاطب رفیعی و همکاران (۲۰۱۱) با استفاده از معیار ماده ۱۴۱ قانون تحارت ایران و متغیرهای نسبتهای مالی، از ۳ روش تحلیل ممیزی ، الگوریتم ژنتیک و شبکه عصبی مصنوعی جهت پیش بینی درماندگی مالی استفاده نمودند که نتایج تحقیقاتشان نشان می دهد که شبکه عصبی مصنوعی بیشترین قدرت و روش تحلیل ممیزی کمتذین قدرت پیش بینی درماندگی مالی را دارند.

منصورفر و همکاران (۱۳۹۳ و ۱۳۹۴) و در دو تحقیق مجزا با استفاده از ترکیبات جریانات نقدی و علامتهای مثبت و منفی این ترکیبات اقدام به پیش بینی درماندگی مالی نمودند. خلیفه سلطانی و اسماعیلی (۱۳۹۳)، به بررسی تاثیر چرخه تجاری بر پایداری مدلهای پیش بینی ورشکستگی پرداختند. ایشان با معیار قرار دادن شمولیت شرکت در ماده ۱۴۱ قانون تحاری به عنوان معیار ورشکستگی و تعیین چرخه تحاری براساس تولید ناخالص

داخلی، دریافتند که چرخه تجاری بر کارایی و پایداری مدلهای بدست آمده از روشهای لاجیت و تحلیل تمایزی (حاصل از ۱۱نسبت مالی) موثر بوده است. همچنین، نتایج تحقیق ایشان نشان حاکی از کارایی بیشتر روش لاجیت در مقایسه با تحلیل تمایزی می باشد.صادقی و همکاران (۱۳۹۳) جهت بررسی تاثیر عوامل کلان اقتصادی و نظام راهبری بر درماندگی مالی شرکتهای تولیدی پذیرفته شده در بورس اوراق بهادار تهران در بازه زمانی ۱۳۸۲ الی ۱۳۸۶ ، شرکتهای مشمول ماده ۱۴۱ قانون تجارت ایران را به عنوان درمانده مالی انتخاب و با استفاده از مدل لاجیت پانلی بررسی نموده اند. مشایخی و گنجی (۱۳۹۳) با انتخاب نمونه ای از شرکتهای مشمول ماده ۱۴۱ و استفاده از ۸ نسبت سود آوری و دو معیار کیفیت سود دریافتند دقت پیش بینی شبکه عصبی مصنوعی برای شرکت های با سود باکیفیت به طور معنی داری بیشتر از شرکتهای با سود بی کیفیت است.کردستانی و تاتلی (۱۳۹۳) با استفاده از مدل تعدیل شده آلتمن، کیفیت

سود را در سه سطح درماندگی، ورشکستگی و سلامت مالی بررسی نمودند.صالحی و بذرگر (۱۳۹۴) به منظور بررسی تاثیر کیفیت سود بر ورشکستگی، با استفاده از دو مدل آلتمن و اولسون به این نتیجه رسیدند که در مدل آلتمن رابطه بین اقلام تعهدی اختیاری و اقلام تعهدی اختیاری تعدیل شده با ورشکستگی معنی دار و مستقیم بوده لیکن این ارتباط در مدل اولسون، معنی دار ولی معموس است.اسماعیل زاده مقری و شاکری (۱۳۹۴) با تفکیک شرکتها به درمانده مال و سالم براساس ماده ۱۴۱ قانون تجارت، استفاده از ۱۲ نسبت مالی و انتخاب نمونه ای از شرکتهای بورسی در فاصله سالهای ۱۳۸۹ تا ۱۳۹۱، توانایی پیش بینی الگوهای شبکه بیزی ساده و تحلیل پوششی داده ها را با هم مقایسه نمودند. نتایج تحقیق ایشان نشان می دهد اگرچه مقایسه دقت کلی دو الگو با یکدیگر در سالهای مورد بررسی (t-2, t-1, t) تفاوت معنی داری را به لحاظ آماری نشان نمی دهد اما به طور کلی دقت پیش بینی الگوی شبکه بیزی ساده در تمامی سالهای مورد بررسی از الگوی تخلیل پوششی داده هر بیشتر است.

روش شناسی تحقیق

در این مطالعه ما تکنیک‌های ANN و DM را برای پیش‌بینی درماندگی مالی(FDP) ادغام می‌کنیم. روش تحقیق همانطور که در شکل ۳ نشان داده شده، بدین شرح است: در مرحله اول ما با مجموعه داده سروکار داریم که اساساً مجموعه عظیمی از رکوردهای شرکت بورس اوراق بهادار است که توسط پیش پردازش داده ها پوشش داده می شود. سپس مجموعه داده‌ها برای از بین بردن ناهماهنگی‌ها و ناهماهنگی‌ها برای بهبود کیفیت، تمیز و پیش پردازش می‌شوند. هدف در این مرحله انتخاب شاخص های مناسب اعم از ضرایب مالی و غیر مالی با استفاده از تحلیل عاملی است. پس از فرآیندهای فوق، فاز بعدی، بارگذاری این نشانگرها و مجموعه قوانین پیش‌بینی است که آماده استفاده در خوشه‌بندی ANN و DM هستند. "انتخاب مدل پیش بینی درماندگی مالی" به تفصیل در بخش های بعدی مورد بحث قرار خواهد گرفت.

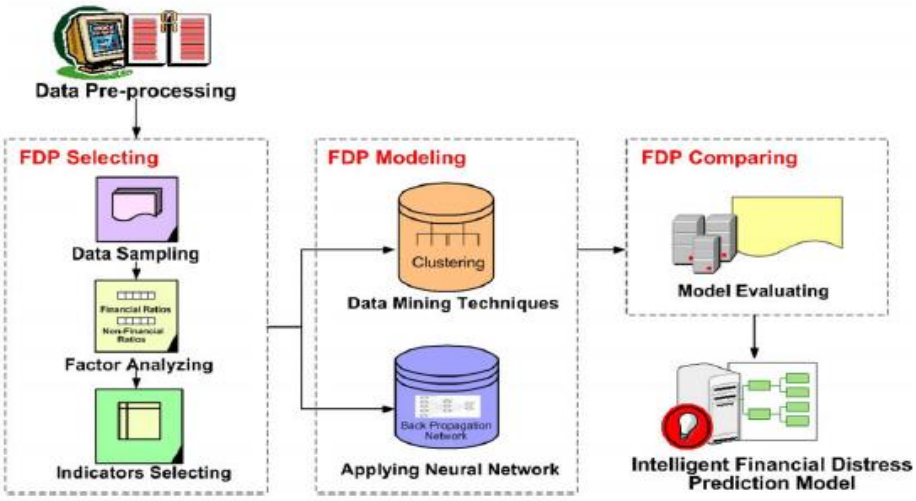

شکل ۳: روش شناسی تحقیق

شکل چپ:پیش پردازش داده ها ،انتخاب مدل پیش بینی درماندگی مالی ،نمونه گیری داده ها ،تحلیل عاملی انتخاب شاخص ها

شکل وسط : انتخاب مدل پیش بینی درماندگی مالی ،تکنیک های داده کاوی (DM) ،استفاده از شبکه عصبی

شکل سمت راست: انتخاب مدل پیش بینی درماندگی مالی، ارزیابی مدل ،مدل هوشمند پیش بینی درماندگی مالی

در مرحله مدل سازی پیش بینی درماندگی مالی، مجموعه داده های صورت های مالی را برای پردازش ANN و DM جمع آوری می کنیم. در رویکرد ANN، از الگوریتم BPN برای کشف قوانین و پیش بینی درماندگی مالیاستفاده می‌کنیم. در رویکرد DM، از تکنیک خوشه بندی برای طبقه بندی و پیش بینی درماندگی مالیاستفاده خواهیم کرد. در مرحله بعد، مجموعه داده های انتخاب شده با استفاده از الگوریتم ها به منظور شناسایی الگوهای بین داده هایی که یک رابطه را نشان می دهند، تجزیه و تحلیل می شود. الگوریتم BPN و خوشه‌بندی برای تعیین الگوها یا قوانین پیش‌بینی درماندگی مالیبه طور جداگانه اعمال می‌شوند.

در مرحله مقایسه مدل های پیش‌بینی درماندگی مالی، ما دقت پیش‌بینی برای BPN و خوشه‌بندی را با استفاده از تحلیل عاملی چندین باره (تحلیل غیر عاملی، تحلیل عاملی اول و تحلیل عاملی دوم) مقایسه می‌کنیم. سپس، مدل پیش‌بینی بحران مالی هوشمند، ساخته و آغاز می‌شود تا مجموعه داده‌های جدید صورت‌های مالی از شرکت بورس اوراق بهادار تأیید شود.

مرحله انتخاب مدل پیش بینی درماندگی مالی

- **داده ها**

نمونه ما حاوی داده های ۶۸ شرکت ایرانی است که در بورس اوراق بهادار فهرست شده اند. دوره نمونه گیری از ۱۳۹۳ به مدت ۷ سال و ماه بوده است. در این تحقیق، ۳۴ شرکت دارای درماندگی مالی با ۳۴ شرکت غیرورشکسته (بدون درماندگی مالی) همسان سازی شدند. این شرکت‌ها بر اساس عدم وجود هرگونه نشانه یا مدرکی مبنی بر اعلام بحران مالی در گزارش‌های حسابرسان، در پایگاه‌های اطلاعاتی مالی و مالیاتی و در بورس اوراق بهادار ، به عنوان شرکت های غیرورشکسته شناخته شدند. البته این امر تضمین نمی‌کند که صورت‌های مالی این شرکت‌ها جعل نشده باشند یا درماندگی مالی این شرکت‌ها در آینده آشکار نشود. بلکه تنها متضمن این است که در طول جستجوی گسترده ای که در راستای این تحقیق صورت گرفته است، هیچ شرکتی که در بحران مالی باشد یافت نشده است. کلیه متغیرهای مورد استفاده در نمونه از صورتهای مالی رسمی مانند ترازنامه و وضعیت درآمد استخراج شده است. این بدان معناست که سودمندی این مطالعه با این واقعیت محدود نمی شود که فقط از داده های شرکت های ایرانی استفاده شده است.

- **متغیرها**

انتخاب متغیرهایی که به عنوان کاندیدای مشارکت در بردار ورودی استفاده می‌شوند بر اساس تحقیقات قبلی مرتبط با موضوع پیش‌بینی درماندگی مالی بود. تحقیقات انجام شده توسط کرکوس و همکاران(۲۰۰۷)، اسپاتیس (۲۰۰۲)، اسپاتیس، دومپوس و زوپونیدیس (۲۰۰۲)، فانینگ و کوگر (۱۹۹۸)، پرسونز (۱۹۹۵)، استیس (۱۹۹۱)، فروز، پارک و پاستنا (۱۹۹۱)، لوبکه، اینینگ، و ویلینگهام (۱۹۸۹) و کینی و مک دانیل (۱۹۸۹)[1] حاوی شاخص های پیشنهادی پیش بینی درماندگی مالی بودند. بنابراین، این مقاله متغیرهای مرتبط را بر اساس تحقیقات قبلی، مجله اقتصادی ایران و پایگاه داده اقتصادی ایران اتخاذ کرد. علاوه بر این، این مقاله ۳۷ متغیر را انتخاب کرد و آنها را در شش نوع عمده طبقه‌بندی کرد: توانایی سودسازی، توانایی ساختارسازی مالی، قابلیت مدیریت کارایی، مدیریت عملکرد، توانایی بازپرداخت بدهی ها و عوامل غیرمالی. جزئیات این شاخص ها که مربوط به هر نوع است، به شرح زیر ارائه می شود:

- توانایی سودسازی: شامل سود قبل از کسر مالیات، بازده کل دارایی ها، بازده حقوق صاحبان سهام، سود هر سهم و نسبت های سود ناخالص.
- توانایی ساختارسازی مالی: شامل بدهی به دارایی ها، سود تضمین شده، ارزش دفتری هر سهم، نسبت اهرم مالی، بدهی به حقوق صاحبان سهام، نسبت بدهی کوتاه مدت و بلندمدت به ارزش دفتری، نسبت دارایی های ثابت به کل دارایی ها، نسبت سود ناخالص به کل دارایی ها، نسبت موجودی به کل دارایی ها، نسبت موجودی به فروش، نسبت سرمایه گذاری و نسبت دارایی های جاری به کل دارایی ها.

1 Kirkos et al. (2007), Spathis (2002), Spathis, Doumpos, and Zopounidis (2002), Fanning and Cogger (1998), Persons (1995), Stice (1991), Feroz, Park, and Pastena 1991), Loebbecke, Eining, and Willingham (1989) and Kinney and McDaniel (1989)

- قابلیت مدیریت کارایی: شامل نرخ گردش موجودی، نرخ گردش حساب دریافتنی، نرخ گردش دارایی‌های ثابت، نرخ گردش کل دارایی‌ها، نرخ گردش حقوق صاحبان سهام و نرخ گردش سرمایه در گردش.
- مدیریت عملکرد: از جمله نسبت رشد سود قبل از کسر مالیات، نسبت رشد سود ناخالص و نسبت رشد فروش.
- توانایی بازپرداخت بدهیها: شامل نسبت جاری، نسبت آنی، نسبت نقدینگی، نسبت جریان نقدی، جریان نقدی به بدهی بلندمدت، جریان نقدی به کل بدهی، و نسبت جریان نقدی به نسبت بدهی کوتاه مدت و بلندمدت.
- عوامل غیرمالی: از جمله نسبت پرداخت سود سهام، نسبت ارزش دفتری قیمت، نسبت سهام وثیقه شده توسط هیئت مدیره و نسبت نگهداری داخلی.

- **تحلیل عاملی**

این مقاله نمونه‌هایی از ۳۴ جفت شرکت دارای بحران مالی و شرکت بدون ورشکستگی که در بورس اوراق بهادار فهرست‌شده بود را بین سال‌های ۱۳۷۸ و ۱۳۸۵ جمع‌آوری کرد. متغیرهای اصلی ۳۷ موردهستند که برای عوامل مدل درماندگی مالی پیش‌بینی‌کننده هستند. این تحقیق از نرم افزار آماری SPSS برای انجام تحلیل عاملی و تحلیل مؤلفه های اصلی (PCA) با چرخش واریماکس (VARIMAX) استفاده کرد تا ساختار عاملی را آسان تر و ساده تر توضیح دهد. اصل انتخاب فاکتورها بر اساس معیارهای کایزر است، به این معنی که مقدار ویژه بزرگتر از ۱، عامل مشترک، قدر مطلق بارهای عاملی، بیشتر از ۰.۵ و اشتراک، بیشتر از ۰.۸ است تا فاکتورهای مناسب به دست آید.

در مجموع ۳۳ نسبت مالی و ۴ نسبت غیرمالی تدوین کردیم. در تلاش برای کاهش ابعاد، ما یک تحلیل عاملی اجرا کردیم تا آزمایش کنیم که آیا تفاوت بین این ۳۷ متغیر برای هر متغیر معنادار است یا خیر. اگر تفاوت معنی دار نبود (بارهای عامل کم یا مقادیر اشتراکی)، متغیر غیر اطلاعاتی در نظر گرفته شد. جدول ۱ بارهای عاملی، اشتراک، مقادیر ویژه و واریانس توضیح داده شده برای هر متغیر را نشان می دهد. در نتیجه، ۱۸ متغیر بارهای عاملی یا مقادیر اشتراکی بالایی را ارائه کردند. این متغیرها برای استفاده در بردار ورودی انتخاب شدند، در حالی که ۱۹ متغیر باقی مانده کنار گذاشته شدند. علاوه بر این، کل واریانس توضیح داده شده ۷۵.۷۷۶ درصد بود. ما از تحلیل عاملی برای پردازش آزمایش برای بار دوم استفاده کردیم. جدول ۲ نشان می دهد که ۵ متغیر کنار گذاشته شدند و کل واریانس توضیح داده شده ۸۵.۲۸۸٪ بود. با توجه به عملکرد بهتر در مقدار کل واریانس توضیح داده شده، می توان فرض کرد که تحلیل عاملی هنوز راه حل بهینه نیست. بنابراین، از تحلیل عاملی برای پردازش آزمایش برای بار سوم استفاده کردیم. جدول ۳ نشان می دهد که دو متغیر کنار گذاشته شده اند و کل واریانس توضیح داده شده ۹۱.۸۷۶ درصد بوده است. بنابراین از تحلیل عاملی برای پردازش آزمایش برای بار چهارم استفاده کردیم. با این حال، جدول ۴ نشان می دهد که هیچ متغیر مناسبی برای کنار گذاشتن وجود ندارد و کل واریانس توضیح داده شده به ۸۸.۲۲۸٪ کاهش یافته است. بنابراین، می‌توان مطمئن بود که تحلیل عاملی بهینه همان تحلیلی بود که بار سوم انجام دادیم، جایی که عملکرد با ۹۱.۸۷۶٪ بالاترین بود.

جدول ۱: نتایج تحلیل عاملی اول

فاکتورها	متغیرها	بارهای عاملی	اشتراک هر متغیر	مقادیر ویژه	واریانس
1	سود هر سهم	0.87	0.919	4.023	10.874
	بازدهی حقوق صاحبان سهام	0.862	0.889		
	بازدهی دارایی	0.85	0.866		
	نسبت رشد سود قبل از کسر مالیات	0.641	0.524		
	سود قبل از کسر بهره و مالیات	0.638	0.814		
2	نسبت جاری	0.762	0.877	3.858	10.428
	نسبت آنی	0.742	0.833		
	حقوق صاحبان سهام به ازای هر سهم	0.631	0.742		
	نسبت نقدینگی	0.624	0.503		
	نسبت سود ناخالص	0.609	0.66		
	نسبت ارزش دفتری	0.352	0.462		
3	نسبت اهرمی	0.949	0.969	3.738	10.103
	نسبت بدهی به حقوق صاحبان سهام	0.948	0.968		
	بدهی / حقوق صاحبان سهام	0.923	0.962		
	نسبت بدهی	0.625	0.82		
4	نرخ گردش کل دارایی ها	0.858	0.824	2.886	7.8
	نرخ گردش حقوق صاحبان سهام	0.798	0.793		
	نرخ گردش دارایی های ثابت	0.635	0.803		
	نسبت سود ناخالص به کل دارایی ها	0.479	0.716		
5	نسبت موجودی به کل دارایی ها	0.899	0.889	2.558	6.912
	نسبت موجودی به فروش	0.848	0.802		
	دارایی های جاری به کل دارایی ها	0.578	0.871		
	نسبت سهام وثیقه شده توسط مدیران	0.422	0.397		
6	نسبت جریان نقدی	0.859	0.873	2.476	6.693
	نسبت جریان نقدی به کل بدهی	0.83	0.823		
	نسبت پرداخت سود سهام	0.514	0.579		
7	نسبت نگهداری داخلی	0.756	0.635	2.039	5.51
	نسبت سرمایه گذاری	0.635	0.755		
	نسبت دارایی های ثابت به کل دارایی ها	-0.607	0.772		
8	سود تضمین شده	0.836	0.778	2.012	

فاکتورها	متغیرها	بارهای عاملی	اشتراک هر متغیر	مقادیر ویژه	واریانس
	جریان نقدی به بدهی بلند مدت	0.827	0.732		
9	نرخ گردش سرمایه در گردش	0.788	0.777		4.571
	نرخ گردش موجودی	-0.714	0.736		
10	نرخ گردش حساب های دریافتنی	0.782	0.693	1.646	4.45
	نسبت رشد سود ناخالص	0.665	0.526		
	نسبت رشد درآمد فروش	0.548	0.641		
11	نسبت جریان نقدی به بدهی کوتاه مدت و بلندمدت	0.871	0.813	1.11	2.999
	کل واریانس		75.766		

جدول ۲: نتایج تحلیل عاملی دوم

فاکتورها	متغیرها	بارهای عاملی	اشتراک هر متغیر	مقادیر ویژه	واریانس
1	بازدهی به دارایی	0.913	0.904	3.497	19.427
	بازدهی حقوق صاحبان سهام	0.903	0.923		
	سود هر سهم	0.897	0.897		
	سود قبل از کسر بهره و مالیات	0.759	0.717		
2	نسبت اهرمی	0.962	0.978	3.492	19.401
	نسبت بدهی به حقوق صاحبان سهام	0.961	0.976		
	بدهی / حقوق صاحبان سهام	0.939	0.968		
	نسبت بدهی	0.656	0.789		
3	نسبت جاری	0.896	0.939	2.296	12.755
	نسبت آنی	0.892	0.94		
4	نسبت موجودی به کل دارایی ها	0.909	0.868		11.659
	نسبت موجودی به فروش	0.891	0.854		
5	نرخ گردش دارایی های ثابت	0.84	0.775	2.076	11.536
	نرخ گردش کل دارایی ها	0.811	0.761		
	دارایی های جاری به کل دارایی ها	0.649	0.869		
6	نسبت جریان نقدی به کل بدهی	0.83	0.835	1.892	10.509
	نسبت جریان نقدی	0.811	0.869		
	نسبت جریان نقدی به بدهی کوتاه مدت و بلندمدت	0.642	0.489		

واریانس	مقادیر ویژه	اشتراک هر متغیر	بارهای عاملی	متغیرها	فاکتورها
	85.288			کل واریانس	

جدول ۳: نتایج تحلیل عاملی سوم

واریانس	مقادیر ویژه	اشتراک هر متغیر	بارهای عاملی	متغیرها	فاکتورها
23.164	3.011	0.993	0.97	نسبت بدهی به حقوق صاحبان سهام	1
		0.994	0.969	نسبت اهرمی	
		0.973	0.943	بدهی / حقوق صاحبان سهام	
21.227	2.759	0.935	0.923	بازدهی دارایی	2
		0.93	0.917	سود هر سهم	
		0.93	0.909	بازدهی حقوق صاحبان سهام	
16.203	2.106	0.929	0.894	نسبت جاری	3
		0.945	0.877	نسبت آنی	
		0.763	0.602	دارایی های جاری به کل دارایی ها	
15.673	2.038	0.934	0.95	نسبت جریان نقدی به کل بدهی	4
		0.943	0.94	نسبت جریان نقدی	
15.609	2.029	0.889	0.927	نسبت موجودی به کل دارایی ها	5
		0.788	0.874	نسبت موجودی به فروش	
	91.876			کل واریانس	

پس از سه بار تحلیل عاملی، ۱۳ متغیر، بار عاملی یا ارزش اشتراکی بالاتری را ارائه کردند. این متغیرها برای استفاده در بردار ورودی انتخاب شدند، در حالی که ۲۴ متغیر باقی مانده کنار گذاشته شدند. متغیرهای انتخاب شده عبارت بودند از: نسبت بدهی به حقوق صاحبان سهام، نسبت اهرمی، بدهی به حقوق صاحبان سهام (DE)، بازده دارایی (ROA)، سود هر سهم (EPS)، بازده حقوق صاحبان سهام (ROE)، نسبت جاری، نسبت آنی، دارایی های جاری. به کل دارایی ها، نسبت جریان نقدی به کل بدهی، نسبت جریان نقدی، نسبت موجودی به کل دارایی ها و نسبت موجودی به فروش.

جدول ۴: نتایج تحلیل عاملی چهارم

فاکتورها	متغیرها	بارهای عاملی	اشتراک هر متغیر	مقادیر ویژه	واریانس
1	نسبت اهرمی	0.962	0.988	2.969	26.989
	نسبت بدهی به حقوق صاحبان سهام	0.961	0.986		
	بدهی / حقوق صاحبان سهام	0.942	0.973		
2	بازدهی دارایی	0.923	0.929	2.779	25.259
	سود هر سهم	0.918	0.923		
	بازدهی حقوق صاحبان سهام	0.91	0.931		
3	نسبت جریان نقدی به کل بدهی	0.937	0.915	2.047	18.613
	نسبت جریان نقدی	0.92	0.916		
	نسبت موجودی به کل دارایی ها	-0.393	0.194		
4	نسبت جاری	0.936	0.975	1.91	17.366
	نسبت آنی	0.921	0.975		
	کل واریانس			88.228	

۵. فاز مدل سازی پیش بینی درماندگی مالی(FDP)

۵-۱. آزمایشات و نتایج ANN

این فرآیند از نسبت‌های مالی و غیر مالی استفاده می‌کند و پس از انجام تحلیل عاملی بار دوم، یک مدل پیش‌بینی درماندگی مالی ایجاد می‌کند. سپس متغیرها به عنوان گره های ورودی ANN بارگذاری می شوند. علاوه بر این، ما همچنین این پارامترهای آزمایشی را برای بررسی ۲ فصل گذشته، ۴ فصل گذشته، ۶ فصل گذشته، و ۸ فصل گذشته قبل از وقوع درماندگی مالی به منظور دقت پیش‌بینی اعمال می‌کنیم. در این آزمایش از BPN به عنوان الگوریتم ANN استفاده خواهیم کرد. علاوه بر این، نمونه آموزشی و نمونه آزمایشی نسبت ۸۰ به ۲۰ را اتخاذ می کنند.

از نظر پیش‌بینی ورشکستگی، دقیق بودن یا نبودن پیش‌بینی به طور معمول با سه کمیت اندازه‌گیری می‌شود: نرخ خطای نوع اول، نرخ خطای نوع دوم و نرخ خطای کل. "نرخ خطای نوع اول" به این معنی است که میزان خطای ریسک نمی تواند شرکت عادی را به عنوان یک شرکت عادی طبقه بندی کند، "نرخ خطای نوع دوم" به این معنی است که میزان خطای ریسک نمی تواند شرکت ورشکسته را طبقه بندی کند، و "نرخ خطای کل" به معنای ترکیب "نرخ خطای نوع اول" و "نرخ خطای نوع دوم" است. جدول ۵ رابطه بین این سه نوع نرخ خطا را نشان می دهد. فرمول هر میزان خطا به شرح زیر است:

۴) نرخ خطای نوع اول : Y2/Y3

۵) نرخ خطای نوع دوم : Y4/Y6

۶) نرخ خطای کل : Y2+Y4/Y9

جدول ۵: رابطه نرخ خطای نوع اول و دوم و میزان خطای کل

		پیش بینی		مجموع
		غیرورشکسته	ورشکسته	
مقادیر واقعی	غیرورشکسته	Y1	Y2	Y3
	ورشکسته	Y4	Y5	Y6
	مجموع	Y7	Y8	Y9

۵-۱-۱ آزمایش با استفاده از تحلیل غیر عاملی

این آزمایش پس از استفاده از ۳۷ متغیر نسبت اصلی که هنوز با تحلیل عاملی به نتیجه نرسیده اند، نتیجه می گیرد همانطور که در جدول ۶ نشان داده شده است، داده های تست دارای نرخ دقت تخمینی به میزان ۸۲.۱۴٪ با نرخ خطای ۱۷.۸۶٪ برای ۲ فصل گذشته هستند. با این حال، میزان دقت به ۶۰٪ کاهش می یابد و میزان خطا در ۸ فصل گذشته به ۴۰٪ افزایش می یابد. هر چه بحران مالی نزدیکتر باشد دقت بالاتری خواهد داشت.

۵-۱-۲ آزمایش با تحلیل عاملی اول

این آزمایش پس از استفاده از ۱۸ متغیر نسبت اصلی این تحقیق که تحت تحلیل عاملی اول قرار گرفته اند به نتیجه می رسد. همانطور که در جدول ۷ نشان داده شده است، داده های تست دارای نرخ دقت تخمینی به میزان ۷۸.۵۷٪ با نرخ خطای ۲۱.۴۳٪ برای ۲ فصل گذشته هستند. با این حال، میزان دقت به ۶۶.۳۶٪ کاهش می یابد و میزان خطا در ۸ فصل گذشته به ۳۳.۶۴٪ افزایش می یابد. مشابه آزمایش فوق، هرچه بحران مالی نزدیکتر باشد، دقت بالاتری خواهد داشت.

۵-۱-۳ آزمایش با تحلیل عاملی دوم

این آزمایش پس از استفاده از ۱۳ متغیر نسبت اصلی این تحقیق که تحت تحلیل عاملی دوم قرار گرفته اند به نتیجه می رسد. همانطور که در جدول ۸ نشان داده شده است، داده های آزمایش دارای نرخ دقت تخمینی تا ۷۵٪ با نرخ خطای ۲۵٪ برای ۲ فصل گذشته هستند. با این حال، میزان دقت به ۶۵.۴۵٪ کاهش می یابد و میزان خطا در ۸ فصل گذشته به ۳۴.۵۵٪ افزایش می یابد. مشابه آزمایش فوق، هرچه بحران مالی نزدیکتر باشد، دقت بالاتری خواهد داشت.

جدول ۶: میزان دقت برای مدل ANN با تحلیل غیر عاملی

	داده آموزشی		داده آزمایشی	
	غیرورشکسته	ورشکسته	غیرورشکسته	ورشکسته
میزان دقت	87.03%	94.44%	92.86%	71.43%
میانگین	90.74%		82.14%	
میزان دقت	89.91%	92.67%	100.00%	55.56%
میانگین	91.28%		0.7778	

	داده آموزشی		داده آزمایشی	
	غیرورشکسته	ورشکسته	غیرورشکسته	ورشکسته
میزان دقت	91.41%	95.71%	87.80%	65.85%
میانگین	93.56%		76.83%	
میزان دقت	95.85%	93.55%	74.55%	45.45%
میانگین	94.70%		60.00%	

جدول ۷: میزان دقت برای مدل ANN با تحلیل عاملی اول

	داده آموزشی		داده آزمایشی	
	غیرورشکسته	ورشکسته	غیرورشکسته	ورشکسته
میزان دقت	90.74%	84.48%	85.71%	71.43%
میانگین	86.11%		78.57%	
میزان دقت	87.16%	85.32%	88.89%	48.15%
میانگین	86.24%		68.52%	
میزان دقت	83.44%	86.50%	65.85%	68.29%
میانگین	84.97%		67.07%	
میزان دقت	93.09%	88.48%	67.27%	65.45%
میانگین	90.78%		66.36%	

جدول ۸: میزان دقت برای مدل ANN با تحلیل عاملی دوم

	داده آموزشی		داده آزمایشی	
	غیرورشکسته	ورشکسته	غیرورشکسته	ورشکسته
میزان دقت	87.04%	77.78%	78.57%	71.43%
میانگین	82.41%		75.00%	
میزان دقت	86.24%	86.24%	92.59%	51.85%
میانگین	86.24%		72.22%	
میزان دقت	87.73%	83.44%	80.49%	48.78%
میانگین	85.58%		64.63%	
میزان دقت	86.18%	81.57%	78.18%	52.73%
میانگین	83.87%		65.45%	

۲-۵. آزمایشات و نتایج داده کاوی (DM)

تجزیه و تحلیل خوشه‌بندی، گروه‌هایی را پیدا می‌کند که هر کدام با دیگری بسیار متفاوت هستند. با این حال، در یک گروه، همه اعضا بسیار شبیه هستند. بر خلاف طبقه بندی، برچسب کلاس هر گروه مشخص نیست. خوشه‌بندی راهی برای تقسیم‌بندی طبیعی داده‌ها به گروه‌ها است، در حالی که طبقه‌بندی راهی برای تقسیم‌بندی داده‌ها با اختصاص دادن آن‌ها به گروه‌ها است. به طور خلاصه، یک روش خوشه‌بندی خوب، خوشه‌هایی با کیفیت بالا با شباهت درون طبقاتی بالا و شباهت بین طبقاتی کم تولید می‌کند (چن و چن، ۲۰۰۶). با این حال، اینکه یک خوشه چقدر خوب است، در نهایت به نظر کاربر بستگی دارد. ما در آزمایش خود، از روش‌های تقسیم‌بندی برای خوشه‌بندی مجموعه داده‌ها برای مدل پیش‌بینی درماندگی مالی استفاده کردیم. روش های پارتیشن بندی، یک پارتیشن از یک پایگاه داده از N شی را به مجموعه ای از k خوشه می سازند. معمولاً آنها با یک پارتیشن اولیه شروع می کنند و سپس از یک استراتژی کنترل تکراری برای بهینه سازی یک تابع هدف استفاده می کنند.

الگوریتم K- میانگین (K-means) (هان و کامبر، ۲۰۰۱) یک الگوریتم خوشه بندی شناخته شده و رایج است. پارامتر ورودی k را می گیرد و داده ها را به k خوشه تقسیم می کند. ابتدا k شی را برای نشان دادن مراکز خوشه انتخاب می کنیم. سپس اشیاء باقیمانده به خوشه ای که مرکز آن به شی نزدیکتر است اختصاص داده می شود. سپس، مقدار میانگین را برای هر خوشه به عنوان مراکز خوشه جدید محاسبه می کند. این فرآیند تا زمانی که تابع معیار همگرا شود تکرار می شود.

همانند آزمایش ANN، این فرآیند نیز از نسبت مالی و غیر مالی استفاده می‌کند و مدل پیش‌بینی درماندگی مالی را پس از تحلیل عاملی دوم می‌سازد. ما از الگوریتم K-means برای بررسی ۲ فصل گذشته، ۴ فصل گذشته، ۶ فصل گذشته و ۸ فصل گذشته قبل از وقوع درماندگی مالی استفاده می کنیم تا از صحت پیش بینی اطمینان حاصل کنیم. پس از اجرای الگوریتم K-means، ما تصمیم گرفتیم ۱۰-۱۵ خوشه را برای تجزیه و تحلیل دقت پیش بینی اتخاذ کنیم.

۱-۲-۵. آزمایش با تحلیل غیر عاملی

این آزمایش پس از استفاده از ۳۷ متغیر نسبت اصلی این تحقیق که هنوز مورد تجزیه و تحلیل عاملی قرار نگرفته اند به نتیجه می رسد. همانطور که در جدول ۹ نشان داده شده است، داده ها دارای نرخ دقت تخمینی به میزان ۷۸.۵۷ درصد با نرخ خطای ۲۱.۴۳ درصد برای ۲ فصل گذشته هستند. با این حال، نرخ دقیق به ۵۶.۳۶٪ کاهش می یابد و میزان خطا به ۴۳.۶۴٪ افزایش می یابد که در ۸ فصل گذشته اندازه گیری شود. هر چه بحران مالی نزدیکتر باشد دقت بالاتری خواهد داشت.

۲-۲-۵. آزمایش با تحلیل عاملی اول

این آزمایش پس از استفاده از ۱۸ متغیر نسبت اصلی این تحقیق که تحت تحلیل عاملی اول قرار گرفته اند به نتیجه می رسد. همانطور که در جدول ۱۰ نشان داده شده است، داده ها دارای نرخ دقت تخمینی تا ۷۵٪ با نرخ خطای ۲۵٪ برای ۲ فصل گذشته هستند. با این حال، نرخ دقیق به ۵۶.۳۶٪ کاهش می یابد و میزان خطا در ۸

فصل گذشته به ۴۳.۶۴٪ افزایش می یابد. مشابه آزمایش فوق، هرچه بحران مالی نزدیکتر باشد، دقت بالاتری خواهد داشت.

۳-۲-۵. آزمایش با تحلیل عاملی دوم

این آزمایش پس از استفاده از ۱۳ متغیر نسبت اصلی این تحقیق که تحت تحلیل عاملی دوم قرار گرفته اند به نتیجه می رسد. همانطور که در جدول ۱۱ نشان داده شده است، داده های آزمایش دارای نرخ دقت تخمینی تا ۷۵٪ با نرخ خطای ۲۵٪ برای ۲ فصل گذشته هستند. با این حال، نرخ دقیق به ۵۶.۳۶٪ کاهش می یابد و میزان خطا در ۸ فصل گذشته به ۴۳.۶۴٪ افزایش می یابد. مشابه آزمایش فوق، هرچه بحران مالی نزدیکتر باشد، دقت بالاتری خواهد داشت.

جدول ۹: میزان دقت برای مدل خوشه‌بندی با تحلیل غیر عاملی

	۱۰ خوشه		۱۱ خوشه		۱۲ خوشه		۱۳ خوشه		۱۴ خوشه		۱۵ خوشه	
	دقت		دقت		دقت		دقت		دقت		دقت	
	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته
میزان دقت	100%	57.14%	50.00%	85.71%	50.00%	85.71%	100%	57.14%	100%	57.14%	85.71%	57.14%
میانگین	78.57%		67.86%		67.86%		78.57%		78.57%		71.43%	
میزان دقت	74.07%	77.78%	88.89%	55.56%	88.89%	55.56%	62.96%	70.37%	88.89%	55.56%	88.89%	55.56%
میانگین	75.93%		72.22%				72.22%		66.67%		72.22%	
میزان دقت	51.22%	85.37%	100%	48.78%	100%	51.22%	100%	51.22%	97.56%	51.22%	60.98%	73.17%
میانگین	68.29%		64.63%		75.61%		75.61%		74.39%		67.07%	
میزان دقت	47.27%	87.27%	85.45%	36.36%	41.82%	78.18%	40.00%	78.18%	50.91%	76.36%	96.36%	16.36%
میانگین	67.27%		60.91%		60.00%		59.09%		63.64%		56.36%	

جدول ۱۰: میزان دقت مدل خوشه‌بندی با تحلیل عاملی اول

	۱۰ خوشه		۱۱ خوشه		۱۲ خوشه		۱۳ خوشه		۱۴ خوشه		۱۵ خوشه	
	دقت		دقت		دقت		دقت		دقت		دقت	
	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته
دقت	100%	35.71%	100.00%	50.00%	100.00%	50.00%	100%	50.00%	100%	50.00%	100.00%	50.00%
میانگین	67.86%		75.00%		75.00%		75.00%		75.00%		75.00%	
دقت	70.37%	51.85%	100.00%	40.74%	100.00%	37.04%	100.00%	40.74%	100.00%	40.74%	100.00%	37.04%
میانگین	61.11%		70.37%		68.52%		70.37%		70.37%		68.52%	
دقت	92.68%	29.27%	100%	19.51%	100%	19.51%	53.66%	51.22%	100.00%	34.15%	100.00%	34.15%
میانگین	60.98%		59.76%		59.76%		52.44%		67.07%		67.07%	
دقت	72.73%	40.00%	100.00%	14.55%	100.00%	21.82%	100.00%	23.64%	100.00%	21.82%	100.00%	21.82%

	۱۰ خوشه		۱۱ خوشه		۱۲ خوشه		۱۳ خوشه		۱۴ خوشه		۱۵ خوشه	
	دقت		دقت		دقت		دقت		دقت		دقت	
	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته
میانگین	56.36%		57.27%		60.91%		61.82%		60.91%		60.91%	

جدول ۱۱: میزان دقت مدل خوشه‌بندی با تحلیل عاملی دوم

	۱۰ خوشه		۱۱ خوشه		۱۲ خوشه		۱۳ خوشه		۱۴ خوشه		۱۵ خوشه	
	دقت		دقت		دقت		دقت		دقت		دقت	
	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته	غیر ورشکسته	ورشکسته
دقت	100.00%	21.43%	100.00%	35.71%	100.00%	50.00%	71.43%	50.00%	71.43%	50.00%	92.86%	57.14%
میانگین	60.71%		67.86%		75.00%		60.71%		60.71%		75.00%	
دقت	100.00%	37.04%	100.00%	37.04%	100.00%	37.04%	100.00%	25.93%	100.00%	51.85%	70.37%	74.07%
میانگین	68.52%		68.52%		68.52%		62.96%		75.93%		72.22%	
دقت	82.93%	65.85%	82.93%	65.85%	82.93%	65.85%	82.93%	65.85%	68.29%	68.29%	68.29%	68.29%
میانگین	74.39%		74.39%		74.39%		74.39%		68.29%		68.29%	
دقت	58.18%	56.36%	83.64%	29.09%	65.45%	60.00%	65.45%	60.00%	61.82%	61.82%	74.55%	56.36%
میانگین	57.27%		56.36%		62.73%		62.73%		61.82%		65.45%	

۶. مرحله مقایسه مدل های پیش بینی درماندگی مالی

پس از پیاده سازی مرحله مدل های پیش بینی درماندگی مالی، مدل های شبکه پس انتشار (BPN) و خوشه بندی را با میزان دقت، میزان خطای نوع ۲ و تحلیل عاملی مقایسه خواهیم کرد. توضیحات مفصل در بخش های بعدی مورد بحث قرار خواهد گرفت.

۱-۶. میزان دقت در رویکردهای شبکه پس انتشار (BPN) و خوشه بندی

همانطور که نتایج فوق را در شکل ۴ مشاهده می کنید، مدل شبکه پس انتشار (BPN) عملکرد پیش بینی را با تحلیل غیر عاملی، پس از تحلیل عاملی اول و دوم ارائه می دهد. نتایج نشان می دهد که نرخ دقت بدترین روند را از ۲ فصل گذشته تا ۸ فصل گذشته قبل از وقوع بحران مالی داشته است. علاوه بر این، مدل شبکه پس انتشار (BPN) نشان می‌دهد که هر چه بحران نزدیک‌تر باشد، میزان دقت بالاتر میرود.

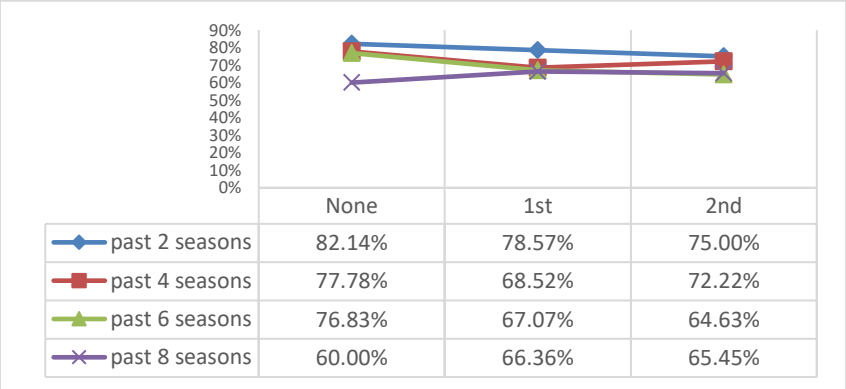

	None	1st	2nd
past 2 seasons	82.14%	78.57%	75.00%
past 4 seasons	77.78%	68.52%	72.22%
past 6 seasons	76.83%	67.07%	64.63%
past 8 seasons	60.00%	66.36%	65.45%

شکل ۴. میزان دقت در مدل شبکه پس انتشار (BPN)

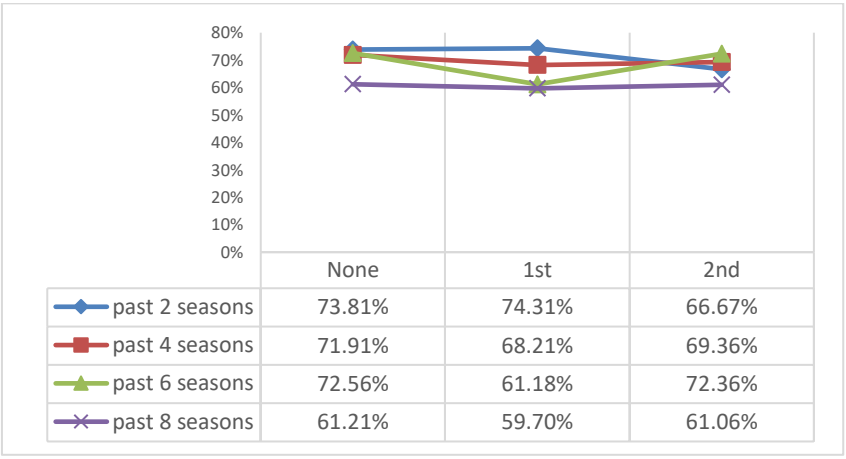

	None	1st	2nd
past 2 seasons	73.81%	74.31%	66.67%
past 4 seasons	71.91%	68.21%	69.36%
past 6 seasons	72.56%	61.18%	72.36%
past 8 seasons	61.21%	59.70%	61.06%

شکل ۵. میزان دقت در مدل خوشه بندی

همانطور که در شکل ۵ مشاهده می شود، مدل خوشه بندی عملکرد پیش بینی را با تحلیل غیر عاملی، پس از تحلیل عاملی اول و دوم نشان می دهد. در نتیجه، نرخ دقت نیز روند بدتر و بدتری را مانند مدل شبکه پس انتشار (BPN) نشان داده است. علاوه بر این، مدل خوشه‌بندی با نزدیک‌تر شدن بحران دقیق‌تر می‌شود.

۲-۶. میزان خطای نوع ۲ برای مدل های شبکه پس از انتشار (BPN) و خوشه بندی

همانطور که نتایج فوق را در شکل ۶ مشاهده می کنید، مدل شبکه پس انتشار (BPN) میزان خطای نوع ۲ را با تحلیل غیر عاملی، پس از تحلیل عاملی اول و دوم ارائه می دهد. این نشان می دهد که نرخ خطای نوع دوم برای هر تحلیل عاملی افزایش می یابد، در حالی که میزان دقت از ۲ فصل گذشته به ۸ فصل گذشته قبل از بحران مالی

کاهش می یابد. علاوه بر این، مدل BPN هرچه به بحران نزدیک‌تر شود دقیق‌تر می‌شود و میزان خطای نوع ۲ کمتر می‌شود.

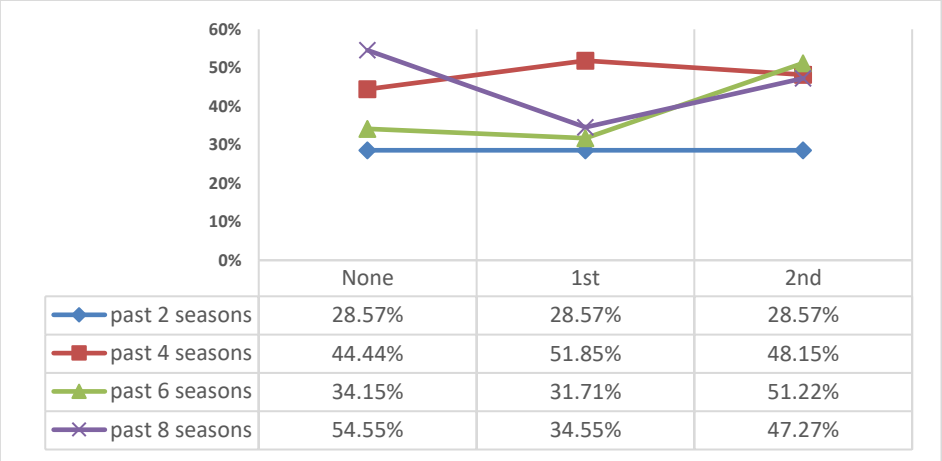

	None	1st	2nd
past 2 seasons	28.57%	28.57%	28.57%
past 4 seasons	44.44%	51.85%	48.15%
past 6 seasons	34.15%	31.71%	51.22%
past 8 seasons	54.55%	34.55%	47.27%

شکل ۶. میزان خطای نوع ۲ در مدل شبکه پس از انتشار (BPN)

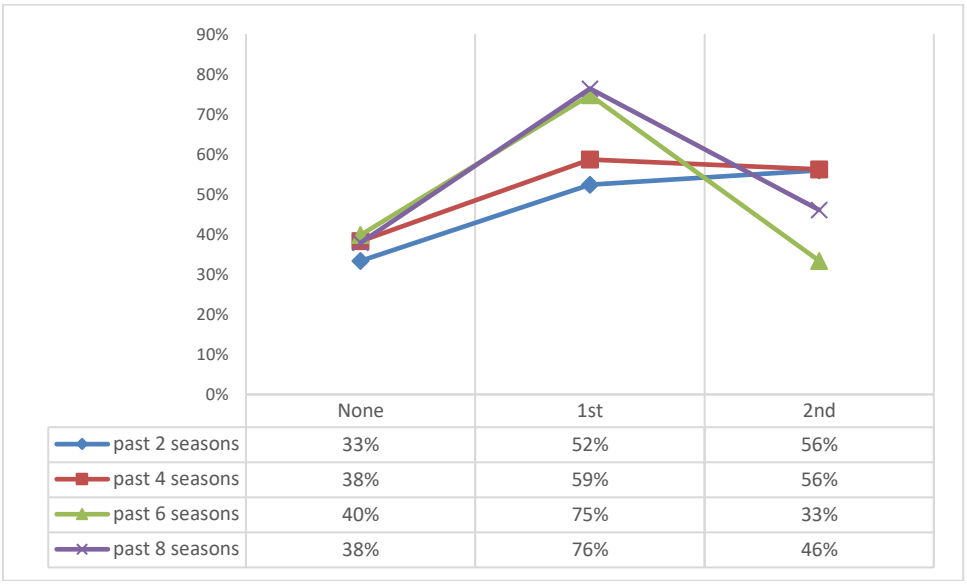

	None	1st	2nd
past 2 seasons	33%	52%	56%
past 4 seasons	38%	59%	56%
past 6 seasons	40%	75%	33%
past 8 seasons	38%	76%	46%

شکل ۷. میزان خطای نوع ۲ در مدل خوشه بندی

همانطور که در شکل ۷ مشاهده می شود، مدل خوشه بندی میزان خطای نوع ۲ را با تحلیل غیر عاملی، پس از تحلیل عاملی اول و دوم ارائه می دهد. این نشان می دهد که نرخ خطای نوع ۲ تقریباً روند افزایشی مشابهی با مدل BPN دارد، در حالی که میزان دقت مشابه مدل BPN کاهش می یابد. تنها استثنا نرخ خطای نوع ۲ است که در تحلیل عاملی دوم نسبت به تحلیل غیر عاملی در ۶ فصل گذشته بهتر است. با این وجود، به طور خلاصه متوجه می‌شویم که هر چه به نقطه بحران نزدیک‌تر باشد، میزان خطای نوع ۲ در مدل خوشه‌بندی کمتر می‌شود.

۳-۶. تحلیل عاملی برای مدلهای BPN و خوشه‌بندی

در این مقایسه، میزان دقت مدل BPN و مدل خوشه‌بندی را برای هر تحلیل عاملی در بیش از ۲، ۴، ۶ و ۸ فصل گذشته میانگین می‌گیریم. در شکل ۸، می بینیم که میزان دقت (تحلیل غیر عاملی) با مدل BPN بهتر از مدل خوشه بندی است، به استثنای ۸ فصل گذشته. در شکل ۹، می‌توانیم ببینیم که نرخ‌های دقت (تحلیل عامل اول) با مدل BPN همگی بهتر از مدل خوشه‌بندی هستند. در شکل ۱۰، می بینیم که میزان دقت (تحلیل عامل دوم) با مدل BPN بهتر از مدل خوشه بندی است، به استثنای ۶ فصل گذشته.

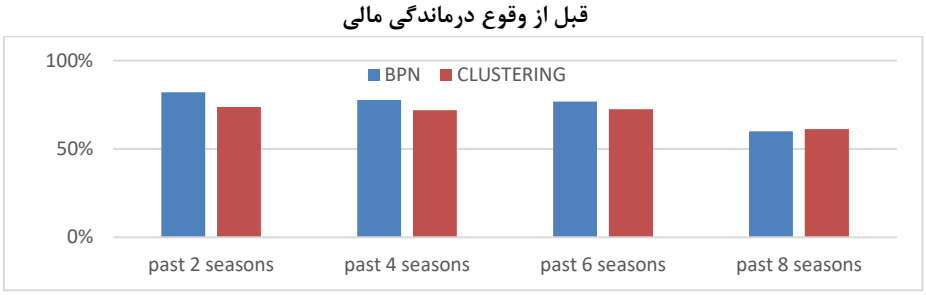

شکل ۸. مقایسه میزان دقت با تحلیل غیر عاملی در مدل های BPN و خوشه‌بندی.

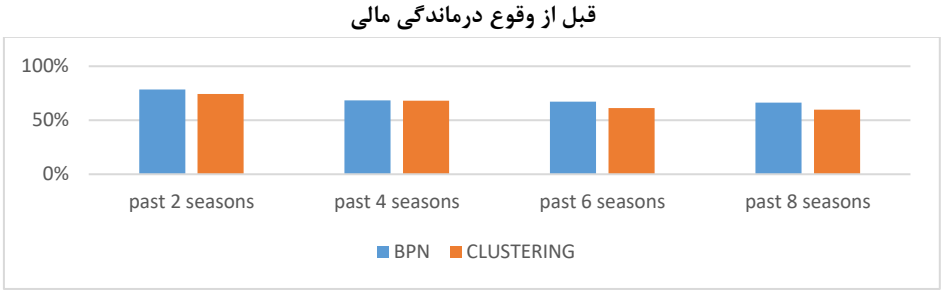

شکل ۹. مقایسه میزان دقت با تحلیل عاملی اول در مدل های BPN و خوشه‌بندی

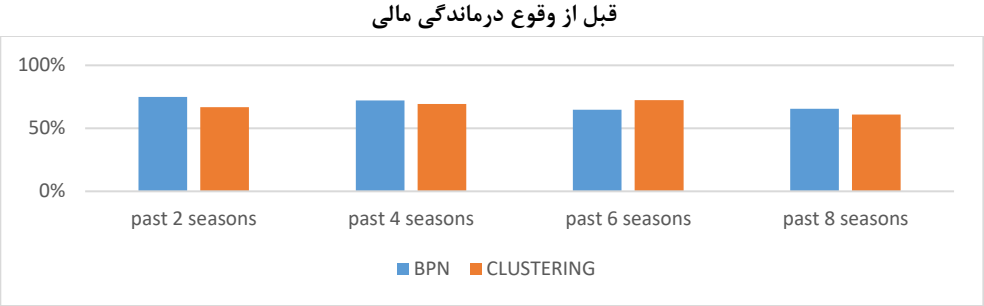

شکل ۱۰. مقایسه میزان دقت با تحلیل عاملی دوم در مدل های BPN و خوشه‌بندی

۷. نتیجه گیری

هدف این تحقیق بررسی نسبت‌های مالی و غیرمالی در صورت‌های مالی بود و از مدل های شبکه پس انتشار (BPN) و خوشه‌بندی برای مقایسه عملکرد پیش‌بینی درماندگی مالیاستفاده کرد تا روش بهتری برای هشدار به شرکت ها و افراد پیدا کند. این تحقیق ۳۴ شرکت را که با بحران مالی مواجه بودند، مورد بررسی قرار داد و آنها را با ۳۴ شرکت عادی که صنعت مشابهی داشتند، مقایسه کرد. علاوه بر این، ما مجموعه داده های لازم را از پایگاه داده بورس اوراق بهادار گرفتیم و آنها را در ۲، ۴، ۶ و ۸ فصل گذشته قبل از وقوع بحران مالی نمونه برداری کردیم. سپس از این داده‌ها برای انجام یک تحلیل عاملی آماری استفاده شد، که روی هر متغیرِ نسبت تولید شده، مدل های شبکه پس انتشار (BPN) و خوشه‌بندی مورد مقایسه قرار گرفت.

پس از انجام آزمایش‌ها، ما چهار مورد مهم را خلاصه کردیم. اول، هرچه زمان بیشتری از تحلیل عاملی استفاده کنیم، نتایج برای مدل های شبکه پس انتشار (BPN) و خوشه‌بندی دقیق‌تر است. در آزمایش‌هایمان، متوجه شدیم که وقتی همه ۳۷ متغیر را با تحلیل غیر عاملی در مدل‌های BPN و خوشه‌بندی اعمال کردیم، می‌توانیم عملکرد پیش‌بینی بهتری به‌جز ۸ فصل گذشته در مدل BPN و برای ۲ فصل گذشته در مدل خوشه بندی به دست آوریم.

دوم، هر چه به زمان بحران مالی واقعی نزدیک‌تر شویم، پیش‌بینی دقیق‌تر خواهد بود. به عنوان مثال، میزان دقت با تجزیه و تحلیل غیر عاملی برای ۲ فصل قبل از بروز درماندگی مالی ۸۲.۱۴٪ در مدل BPN است، در حالی که این میزان در ۸ فصل فقط ۶۰٪ است. نتایج برای مدل خوشه‌بندی مشابه است، که در آن میزان دقت با تحلیل غیرعاملی برای ۲ و ۸ فصل قبل از وقوع بحران مالی به ترتیب ۷۳/۸۱ و ۶۱/۲۱ درصد است.

سوم، بیشتر سرمایه گذاران نگران میزان خطای نوع ۲ هستند و از سرمایه گذاری در این شرکت ها اجتناب می کنند. نتایج تجربی ما نشان می‌دهد که تحلیل عاملی، پیش‌بینی‌های خطای طبقه‌بندی شرکت‌های دارای بحران مالی بالقوه را به عنوان یک شرکت عادی افزایش می‌دهد. علاوه بر این، ما همچنین دریافتیم که میانگین میزان خطای نوع ۲ در مدل خوشه‌بندی بالاتر از مدل BPN است. بنابراین، عملکرد پیش‌بینی برای مدل خوشه‌بندی بیشتر از مدل BPN تحت تأثیر قرار می‌گیرد.

در نهایت، مدل BPN دقت پیش‌بینی بهتری نسبت به مدل خوشه‌بندی DM در توسعه یک مدل پیش‌بینی درماندگی مالیبه دست می‌آورد، با این استثنا که نرخ دقت (تحلیل غیرعاملی) برای مدل ۸ فصل گذشته و نرخ دقت (تحلیل عامل دوم) برای ۶ فصل گذشته با مدل BPN کمتر است.

در تحقیقات آینده، تکنیک‌های هوش مصنوعی اضافی، مانند سایر مدل‌های شبکه عصبی، استخراج طبقه‌بندی، الگوریتم‌های ژنتیک و غیره نیز می‌توانند به کار گرفته شوند. و مطمئناً، محققان می توانند سیستم را به گونه ای گسترش دهند که با مجموعه داده های مالی بیشتری مقابله کند.

فهرست منابع

واقفی، سیدحسام، جوانشیری، حسین (۱۴۰۱) " تحلیل محتوای درماندگی مالی" مطالعات حسابداری و حسابرسی، انجمن حسابداری ایران، شماره ۴۱ ،۸۴-۶۵

حاجیها، زهره، صابری روچی، محمدرضا (۱۴۰۰) "متن کاوی و پیش بینی درماندگی مالی". مطالعات حسابداری و حسابرسی، انجمن حسابداری ایران، شماره ۳۸ ،۳۹-۵

رهنمای رودپشتی، فریدون،۱۳۹۹، نهمین کنفرانس انجمن مهندسی مالی، منظومه تاب آوری کسب و کارها مبتنی بر ابزارهای نوآورانه مالی،۱۰۴

رهنمای رودپشتی، فریدون،۱۳۹۸،بررسی و ارزیابی ارزش افزوده اقتصادی و ارزش افزوده بازار در مدیریت ارزش افزوده سهامداران،مجله پژوهشگر(مدیریت)، دوره ۷، ۷۹-۷۰

پوراسد، سعید. (۱۳۹۵). تاثیر کوتاه بینی مدیریتی بر کارایی شرکت ها با نقش تعدیل کننده کیفیت حاکمیت شرکتی در شرکت های بورس اوراق بهادار تهران. پایان نامه کارشناسی ارشد، دانشگاه ارومیه.

اسماعیل زاده مقری، علی و شاکری، هاجر (۱۳۹۴). پیش بینی درماندگی مالی شرکت های پذیرفته شده در بورس اوراق بهادار تهران با استفاده ازشبکه بیزی ساده و مقایسه آن با تحلیل پوششی داده ها. فصلنامه مهندسی مالی و مدیریت اوراق بهادار، ۵(۲۲): ۲۷-۱.

منصورفر، غلامرضا؛ غیور، فرزاد؛ اسدی، مریم. (۱۳۹۵). اثر تعدیل گر کیفیت سود در پیش بینی درماندگی مالی شرکت های پذیرفته شده در بورس اوراق بهادار تهران. فصلنامه راهبرد مدیریت مالی، ۴(۴): ۴۴-۲۵.

منصورفر، غلامرضا؛ غیور، فرزاد و لطفی، بهناز (۱۳۹۴). توانایی ماشین بردار پشتیبان در پیش بینی درماندگی مالی. پژوهش های تجربی حسابداری، ۳(۱۱): ۲۳۵-۲۱۷.

منصورفر، غلامرضا؛ غیور، فرزاد و لطفی، بهناز (۱۳۹۲). ترکیب اجزای جریان نقد و پیش بینی درماندگی مالی در بورس اوراق بهادار تهران. تحقیقات حسابداری و حسابرسی، ۴(۱۸): ۸۷-۷۴.

واقفی، سیدحسام، جوانشیری، حسین (۱۴۰۱) " تحلیل محتوای درماندگی مالی" مطالعات حسابداری و حسابرسی، انجمن حسابداری ایران، شماره ۴۱ ،۸۴-۶۵

حاجیها، زهره، صابری روچی، محمدرضا (۱۴۰۰) "متن کاوی و پیش بینی درماندگی مالی ."مطالعات حسابداری و حسابرسی، انجمن حسابداری ایران، شماره ۳۸ ،۳۹-۵

رهنمای رودپشتی، فریدون،۱۳۹۹، نهمین کنفرانس انجمن مهندسی مالی، منظومه تاب آوری کسب و کارها مبتنی بر ابزارهای نوآورانه مالی،۱۰۴

رهنمای رودپشتی، فریدون،۱۳۹۸،بررسی و ارزیابی ارزش افزوده اقتصادی و ارزش افزوده بازار در مدیریت ارزش افزوده سهامداران،مجله پژوهشگر(مدیریت)، دوره ۷، ۷۹-۷۰ .

Primandari, A. H. (2021, October). Building an Initiation of Financial Reporting System Using Blockchain and Classification Analysis to Financial Distress. In The 2nd International Seminar on Science and Technology (ISSTEC 2019) (pp. 193-199).

Atlantis Press.Wu, L.; Shao, Z.; Yang, C.; Ding, T.; Zhang, W. The Impact of CSR and Financial Distress on Financial Performance—Evidence from Chinese Listed Companies of the Manufacturing Industry. Sustainability 2020, 12, 6799

Chen, S.; Shen, Z.-D. Financial Distress Prediction Using Hybrid Machine Learning Techniques. Asian J. Econ. Bus. Account. 2020, 16, 1–12

Altman, E. L. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. The Journal of Finance, 23(3), 589–609.

Altman, E. L., Edward, I., Haldeman, R., & Narayanan, P. (1977). A new model to identify bankruptcy risk of corporations. Journal of Banking and Finance, 1,
29–54.

Beaver, W. (1966). Financial ratios as predictors of failure, empirical research in accounting: Selected studied. Journal of Accounting Research, 71–111.

Blum, M. (1974). Failing company discriminant analysis. Journal of Accounting Research, 1–25.

Chen, T. (2007). Incorporating fuzzy c-means and a back-propagation network ensemble to job completion time prediction in a semiconductor fabrication factory. Fuzzy Sets and Systems, 158(19), 2153–2168.

Chen, A. P., & Chen, C. C. (2006). A new efficient approach for data clustering in electronic library using ant colony clustering algorithm. The Electronic Library, 24(4), 548–559.

Chun, S. H., & Park, Y. J. (2006). A new hybrid data mining technique using a regression case based reasoning: Application to financial forecasting. Expert Systems with Applications, 31(2), 329–336.

Deng, W. J., Chen, W. C., & Pei, W. (2007). Back-propagation neural network based importance–performance analysis for determining critical service attributes. Expert Systems with Applications. Doi: 10.1016/j.eswa.2006. 12.016.

Dimitras, A. I., Zanakis, S. H., & Zopounidis, C. (1996). A survey of business failure with an emphasis on prediction methods and industrial applications. European Journal of Operational Research, 90(3), 487–513.

Fanning, K., & Cogger, K. (1998). Neural network detection of management fraud using published financial data. International Journal of Intelligent Systems in Accounting, Finance and Management, 7(1), 21–24.

Feroz, E., Park, K., & Pastena, V. (1991). The financial and market effects of the SECs accounting and auditing enforcement releases. Journal of Accounting Research, 29(Suppl.), 107–142.

Han, J., & Kamber, M. (2001). Data mining: Concepts and techniques. San Francisco, CA, USA: Morgan Kaufmann.

Huang, M. J., Chen, M. Y., & Lee, S. C. (2007). Integrating data mining with casebased reasoning for chronic diseases prognosis and diagnosis. Expert Systems with Applications, 32(3), 856–867.

Huang, Y. P., Hsu, C. C., & Wang, S. H. (2007). Pattern recognition in time series database: A case study on financial database. Expert Systems with Applications, 33(1), 199–205.

Hua, Z., Wang, Y., Xu, X., Zhang, B., & Liang, L. (2007). Predicting corporate financial distress based on integration of support vector machine and logistic regression.Expert Systems with Applications, 33(2), 434–440.

John, S. G., & Robert, W. I. (2001). Tests of the generalizability of altman's bankruptcy prediction model. Journal of Business Research, 54, 53–61.

Jost, A. (1993). Neural networks: A logical progression in credit and marketing decision system. Credit World, 81(4), 26–33.

Kinney, W., & McDaniel, L. (1989). Characteristics of firms correcting previously reported quarterly earnings. Journal of Accounting and Economics, 11(1), 71–93.

Kirkos, E., Spathis, C., & Manolopoulos, Y. (2007). Data mining techniques for the detection of fraudulent financial statements. Expert Systems with Applications, 32(4), 995–1003.

KO, P. C., & Lin, P. C. (2006). An evolution-based approach with modularized evaluations to forecast financial distress. Knowledge-Based Systems, 19(1), 84–91.

Laitinen, E. K., & Laitinen, T. (2000). Bankruptcy prediction application of the Taylor's expansion in logistic regression. International Review of Financial Analysis, 9, 327–349.

Lee, T. L. (2004). Back-propagation neural network for long-term tidal predictions.Ocean Engineering, 31(2), 225–238.

Loebbecke, J., Eining, M., & Willingham, J. (1989). Auditor's experience with materialirregularities: Frequency, nature and detectability. Auditing: A Journal of Practice and Theory, 9, 1–28.

Medsker, L., & Liebowitz, J. (1994). Design and development of expert systems and neural networks. New York: Macmillan.

Meyer, P. A., & Pifer, H. (1970). Prediction of bank failures. The Journal of Finance, 25,853–868.

Mitra, S., Pal, S. K., & Mitra, P. (2002). Data mining in soft computing framework: A survey. IEEE Transactions Neural Networks, 13(1), 3–14.

Panda, S. S., Chakraborty, D., & Pal, S. K. (2007). Flank wear prediction in drilling using back-propagation neural network and radial basis function network.Applied Soft Computing. doi:10.1016/j.asoc.2007.07.003.

Persons, O. (1995). Using financial statement data to identify factors associated with fraudulent financial reporting. Journal of Applied Business Research, 11(3), 38–46.

Ronald, J. W., Rumelhart, D. E., & Hinton, G. E. (1986). Learning internal representations by error propagation. In E. David Rumelhart & J. A. McClelland (Eds.). Parallel distributed processing: Explorations in the microstructure of cognition (Vol. 1). Cambridge: MIT Press/Bradford Books.

Spathis, C. (2002). Detecting false financial statements using published data: Some evidence from Greece. Managerial Auditing Journal, 17(4), 179–191.

Spathis, C., Doumpos, M., & Zopounidis, C. (2002). Detecting falsified financial statements: A comparative study using multicriteria analysis and multivariate statistical techniques. The European Accounting Review, 11(3), 509–535.

Stice, J. (1991). Using financial and market information to identify pre-engagement market factors associated with lawsuits against auditors. The Accounting Review, 66(3), 516–533.

Werbos, P. (1974), Beyond regression: New tools for prediction and analysis in the behavioral science, Ph.D. Thesis, Committee on Applied Mathematics, Harvard University, Cambridge, MA.

Wu, D., Yang, Z., & Liang, L. (2006). Using DEA-neural network approach to evaluate branch efficiency of a large Canadian bank. Expert Systems with Applications, 31, 108–115.

Yılmaz, B., & Cunedioglu, U. (2007). Source localization of focal ventricular arrhythmias using linear estimation, correlation, and back-propagation networks. Computers in Biology and Medicine, 37(10), 1437–1445

Financial Economics
Vol. (15) Issue (59) Autumn 2026

Testing the measurement power of neural network techniques and data mining techniques in predicting financial distress

Seyedalireza Rouintan
PhD Student, Department of Finance, Research & Science Branch, Islamic Azad University, Tehran, Iran
go2s_alireza@yahoo.com

Kambiz Peykarjou
Assistant Professor, Department of Economics, Faculty of Management, Science and Research Branch, Tehran, Iran (corresponding author)
k.peykarjou@srbiau.ac.ir

Maryam Khalili Araghi
Assistant Professor, Department of Financial Management, Faculty of Management, Islamic Azad University, Science and Research Branch, Tehran, Iran.
m.khaliliaraghi @gmail.com

Abstract
To improve the accuracy of the financial distress forecasting model, this article evaluates the sample companies in a new scope by discarding some common regulations in the stock exchange company - which have been violated by those companies that were stopped and suspended. The use of financial and non-financial indicators together, and also factor analysis to extract compatible variables and artificial neural network (ANN) and data mining (DM) techniques to build a financial distress prediction model are among the most important fundamentals of the above research structure. A total of 37 indicators have been tested in 68 companies admitted to the stock market as prototypes, in different methods and techniques.
The obtained results show that (1) ANN and DM approaches in factor analysis achieve less accuracy, (2) the closer we get to the actual occurrence of financial distress, the more accurate we get (achieving 82.14% accuracy for the two seasons before the occurrence of financial distress), (3) Factor analysis increases the error of classifying helpless companies in the category of normal companies. (4) Finally, with the development of financial distress prediction model, the accuracy of ANN approach is more than DM approach. In the end, this article considers the use of artificial intelligence (AI) approach in the financial engineering model to be a more suitable method for predicting the potential financial distress of a company.
Keywords: financial engineering approach, comprehensive financial distress prediction model, artificial neural networks, data mining.