



قدرت شبکه عصبی پیچشی در پیش‌بینی درماندگی مالی^۱

امین امینی مهر^۲، هانیه حکمت^۳

تاریخ پذیرش: ۱۴۰۱/۰۴/۲۳

تاریخ دریافت: ۱۴۰۰/۱۲/۲۵

چکیده

در این پژوهش ضمن نگاه بر سیر تکامل ادبیات پیش‌بینی درماندگی مالی، به ارائه یک مدل یادگیری عمیق پرداخته شده است. در این روش به شکلی مراحلی که روش‌های پیشین برای پیش‌بینی درماندگی طی کرده‌اند، کوتاه‌تر و خودکارتر شده است. در نهایت، به مقایسه دقت پیش‌بینی مدل توسعه داده شده با مدل‌های پیشین در این حوزه پرداخته شده است. در این پژوهش یک شبکه عصبی پیچشی به‌عنوان یک مدل یادگیری عمیق که داده‌های ۱۴ متغیر مرتبط با پیش‌بینی درماندگی مالی را در طول ۳ سال متوالی واکاوی می‌کند، برای پیش‌بینی درماندگی مالی مورد استفاده قرار گرفته است. بدر این راستا، به‌منظور جلوگیری از خطاهای احتمالی تعمیم‌پذیری، از روش K-fold برای نمونه‌گیری فرعی استفاده شده است که داده‌های ۳۰۰ نمونه را مورد بررسی قرار می‌دهد. در نهایت، با استفاده از آزمون ناپارامتریک Wilcoxon به بررسی معنی‌دار بودن اختلاف دقت پیش‌بینی ارائه شده میان مدل توسعه داده شده و مدل‌های پیشین پرداخته شده است. نتایج این پژوهش نشان می‌دهد مدل شبکه عصبی پیچشی به شکل معنی‌داری در سطح اطمینان ۹۵ درصد مدل‌های پیش‌بینی درماندگی سابق از جمله رگرسیون لجستیک و ماشین بردار پشتیبان را در دقت پیش‌بینی شکست می‌دهد.

واژگان کلیدی: درماندگی مالی، پیش‌بینی، شبکه عصبی پیچشی، یادگیری عمیق.

طبقه‌بندی موضوعی: G33, G38, G34, E44, C19

۱. کد DOI مقاله: 10.22051/JFM.2023.39916.2669

۲. دانشجوی کارشناسی‌ارشد، دانشگاه ارشد دماوند، تهران، ایران. (نویسنده مسئول). Email: aminaminimehr@outlook.com

۳. استادیار، گروه حسابداری، دانشکده علوم اجتماعی و اقتصادی، دانشگاه الزهرا، تهران، ایران. Email: h.hekmat@alzahra.ac.ir

مقدمه

به نوعی ذی‌نفعان را راجع به وضعیت یک شرکت آگاه سازند، بسیار حائز اهمیت است (سعیدی و آقایی، ۱۳۸۸). نکته مهم در خصوص چنین مطالعه‌ای در ایران، اولاً، سطحی و غیردقیق بودن مطالعات داخلی انجام شده تا به حال و ثانیاً، نشان دادن اهمیت دانش موجود در داده‌های صورت‌های مالی است. علاوه بر آنچه که بیان شد، نیاز به تصمیم‌گیری سریع در مسائل مالی برای پژوهشگران رشته مالی مسئله پر اهمیتی بوده است؛ بنابراین پژوهش‌گران به دنبال راه و روش‌هایی هستند که بتوان از آن طریق یک خط‌مشی در خصوص سرمایه‌گذاری و حفظ منافع مالی خود داشته باشند. همچنین نکته مهم در این خصوص این است که اولاً متغیرهای مناسبی که توان پیش‌بینی خوبی داشته باشند انتخاب شود و سپس، دقت روش پیش‌بینی و سرعت‌سنجش روابط میان متغیرها نیز سریع باشد. به همین دلیل پژوهش‌هایی نیز فقط با تمرکز بر روی انتخاب ویژگی‌های مناسب برای استفاده در مدل‌های پیش‌بینی درمان‌دگی به چاپ رسیده است (تاج مزینانی، فلاح‌پور و باجلان، ۱۳۹۴). در این پژوهش ابتدا به بیان سیر تحول ادبیات پیش‌بینی درمان‌دگی مالی پرداخته و سپس با ارائه یک مدل نوین شبکه عصبی پیچشی، اقدام به پیش‌بینی درمان‌دگی مالی داده‌های جمع‌آوری شده از شرکت‌های پذیرفته شده در بورس تهران شده است. نکته مهم این است که در این پژوهش به نوعی تلاش بر حذف کردن یکی از مراحل انجام پیش‌بینی درمان‌دگی در پژوهش‌های پیشین شده است. هدف نهایی این پژوهش بررسی این است که آیا مدل توسعه داده شده در آن می‌تواند از میان متغیرها دانشی استخراج کند که سایر مدل‌های استفاده شده در این حوزه نتوانسته‌اند استخراج کنند. به بیانی دیگر هدف این است که ببینیم آیا مدل‌های یادگیری عمیق می‌توانند دقت بیشتری در پیش‌بینی درمان‌دگی مالی داشته باشند یا خیر. ادامه این پژوهش به شرح زیر تقسیم‌بندی شده است. ابتدا به بررسی مهم‌ترین تعاریف ارائه شده برای درمان‌دگی مالی از سال ۱۹۶۶ به بعد پرداخته شده است. همچنین، به بیان مهم‌ترین مدل‌های بررسی درمان‌دگی مالی از جمله مدل‌های کلاسیک و بعد از آن مدل‌های نوین این حوزه پرداخته شده است. بعد از آن به تعریف مسئله دسته‌بندی با ناظر، چگونگی فرایند پردازش مدل شبکه عصبی پیچشی، بررسی روش K-fold و تعریف آزمون Wilcoxon پرداخته شده است. سپس، با بررسی مرحله‌به‌مرحله روش انجام پژوهش، به بررسی نتایج به‌دست‌آمده و مقایسه نتایج با مدل‌های پایه در حوزه پیش‌بینی درمان‌دگی پرداخته شده است.

مبانی نظری پژوهش

تا به حال تعاریف متفاوتی در مورد درمان‌دگی ارائه شده است. بیور^۱ در سال ۱۹۶۶ بیان کرد که وقوع حداقل یکی از موارد نکول بازپرداخت اوراق، نکول بازپرداخت سود صاحبان سهام و کاهش بیش از حد وجه نقد حساب‌های بانکی نشانه درمان‌دگی شرکت است (بیور ۱۹۶۶). در ادامه محققان دیگری که برای درمان‌دگی تعاریفی را ارائه نمودند بر مبنای یکی از شرایط بیان شده توسط بیور مدل خود را بنا کرده و ارائه نمودند. یکی از تعاریف در مورد درمان‌دگی مالی را گوردون^۲ در سال ۱۹۷۱ میلادی بیان نمود. او معتقد

1. Beaver
2. Gordon

بود شرکت‌هایی که سودآوری آن‌ها کاهش یابد و احتمال عدم باز پرداخت تعهداتشان افزایش یابد، درمانده خواهند بود (گوردون، ۱۹۷۱). اگر چه تعریف گوردون به خوبی قابل کمی‌سازی نبود و معیارهای اندازه‌گیری کافی نداشت، اما خط‌مشی خوبی برای بررسی وضعیت شرکت‌ها ارائه کرد. اما در سال ۱۹۹۹ میلادی ویتاکر^۱ تعریفی قابل کمی‌سازی و سنجش را برای بررسی درماندگی شرکت‌ها بیان نمود (ویتاکر، ۱۹۹۹). او اذعان داشت با محاسبه برآیند جریان‌های ورودی و خروجی نقدی شرکت و مقایسه آن با هزینه‌های بهره بلندمدت، می‌توان وقوع درماندگی یا عدم‌وقوع آن را در یک شرکت اندازه‌گیری نمود. در نهایت، به‌عنوان خلاصه‌ای از دیدگاه‌های متفاوت برای تعریف درماندگی می‌توان به «اعلان عمومی درماندگی» (زیمجوزگی^۲، ۱۹۸۴ و دیکن^۳، ۱۹۷۲)، «عدم‌توانایی باز پرداخت یک بدهی» (دیکن، ۱۹۷۲، بلوم^۴، ۱۹۷۴ و وارد^۵ و فاستر^۶، ۱۹۷۷) و «نیاز به تغییر ساختار قانونی شرکت» اشاره کرد (آلمن^۷، ۱۹۶۸، وارد و فاستر ۱۹۷۷ و فاستر ۱۹۸۶).

در ایران تعریف درماندگی و معیار سنجش آن کمی متفاوت است. از آنجا که در پژوهشی توسط راعی و فلاح‌پور معیار درماندگی را شرکت‌هایی می‌دانند که مشمول ماده ۱۴۱ قانون تجارت بوده‌اند، این مبنا در بسیاری از پژوهش‌های بعد از آن‌ها نیز معیار قرار گرفته است (راعی و فلاح‌پور، ۱۳۸۷). نکته بسیار مهم در مورد درماندگی این است که بسیاری از پژوهشگران درماندگی را معادل با ورشکستگی می‌دانند؛ اما این در حالی است که درماندگی صرفاً یک مرحله از ورشکستگی است و ممکن است لزوماً درماندگی مالی منتج به ورشکستگی نشود. با صرف‌نظر از دیدگاه‌های متفاوت راجع به درماندگی، میان پژوهشگران این شاخه اتفاق نظری مبنی بر نیاز بر وجود یک مدل پیش‌بینی یا مدل هشداردهنده وجود داشت. آن‌ها معتقد بودند که دولت‌ها می‌توانند با داشتن یک مدل پیش‌بینی ریسک به اقدامات لازم بپردازند. همچنین سرمایه‌گذاران می‌توانند با استفاده از پیش‌بینی درماندگی سرمایه خود را حفظ کنند (چو^۸ و دیگران، ۲۰۱۷).

بنا بر وجود دغدغه‌های ذکر شده، بیور اولین مدل متشکل از ۲ نسبت مالی را که از میان ۳۰ نسبت مالی انتخاب شده بود تخمین زد (بیور، ۱۹۶۶). در ادامه تحقیقات بیور، آلمن با ارائه یک فرمول که امروزه با عنوان Z-Altman می‌شناسیم یک شاخص کاملاً کمی ارائه نمود. او در شاخص خود از ۵ نسبت مالی (که از میان ۲۲ نسبت مالی اولیه انتخاب شده بود) استفاده نمود که به شرح زیر است (آلمن، ۱۹۶۸).

نسبت ۱: سرمایه در گردش تقسیم بر دارایی کل

نسبت ۲: سود انباشته تقسیم بر دارایی کل

نسبت ۳: سود قبل از بهره و مالیات تقسیم بر دارایی کل

1. Whitaker
2. Zmijewski
3. Deakin
4. Blum
5. Ward
6. Foster
7. Altman
8. Chou

نسبت ۴: نسبت ارزش بازار حقوق صاحبان سهام به کل بدهی

نسبت ۵: نسبت فروش کل به دارایی کل

آلتمن با استفاده از معادله رگرسیون خطی ای که تخمین زد به وزن‌هایی (ضریب) دست‌یافت که معادله‌ای به شرح رابطه ۱ را نشان می‌داد:

$$Z = 1/2 (\beta_1) + 1/4 (\beta_2) + 3/3 (\beta_3) + 0/6 (\beta_4) + 1/0 (\beta_5) \quad \text{رابطه ۱}$$

بعد از آلتمن، مارتین در سال ۱۹۷۷ با استفاده از رگرسیون لجستیک اقدام به ارائه اولین مدل دسته‌بندی هشداردهنده در حوزه بانکداری نمود. او نیز از میان ۲۵ نسبت مالی ۶ تا از کلیدی‌ترین آن‌ها را انتخاب نمود و با آنها مدل خود را تدوین کرد (مارتین، ۱۹۷۷).

اگرچه مدل‌های ارائه شده به‌خصوص شاخص Z آلتمن دارای محدودیت‌هایی بود، اما بسیار مورد توجه قرار گرفت و مبنای بسیاری از پژوهش‌های بعد از خود شد. اولاً، Z آلتمن صرفاً از ۵ نسبت مالی استفاده می‌کند و احتمالاً با افزایش متغیرهای بیشتر با ازدست‌دادن درجه آزادی و به اندازی کافی افزایش نیافتن معیار نیکویی برازش، این تخمین مناسب‌تر نخواهد شد. ثانیاً، این شاخص صرفاً روابط خطی میان متغیرهای مستقل و ریسک درماندگی را می‌سنجد، درحالی‌که ممکن است میان متغیرهای توضیح‌دهنده ریسک و ریسک درماندگی روابط غیرخطی وجود داشته باشد. در نهایت، ضریب‌هایی که آلتمن در تخمین خود به دست آورد مطابق با داده‌های شرکت‌ها و کسب‌وکارهایی است که بر روی آن پژوهش کرده بود و نمی‌تواند مبنایی جهان‌شمول برای بررسی ریسک‌های مربوط به درماندگی شرکت‌ها باشد و این موضوع می‌تواند در کشورهایی مثل ایران تفاوت قابل توجهی را در خطای سنجش ریسک ایجاد کند. بنابراین، شاید لازم است که ضرایبی که آلتمن در مدل خود ارائه کرده بود برای مناطق و ساختارهای اقتصادی متفاوت بومی‌سازی شود.

با گسترش تکنیک‌ها و مدل‌های پیشرفته داده‌کاوی و هم‌زمان شدن با پیشرفت توان پردازش‌گرهای رایانه‌ای بسیاری از پژوهش‌ها به شکلی دیگر تغییر کرده‌اند. این تحول آن‌قدر همه‌گیر است که سالانه تعداد زیادی پژوهش در بسیاری از علوم از جمله مالی با استفاده از تکنیک‌ها و الگوریتم‌های هوش مصنوعی به چاپ می‌رسد (راوی کومار^۲ و راوی^۳، ۲۰۰۷). یکی از شاخه‌های بسیار مورد توجه در علم مالی که با استفاده از الگوریتم‌های متفاوت پوشش داده شده است پیش‌بینی درماندگی شرکت‌ها است. از پیش‌تازان این شاخه از مدل‌سازی مالی را می‌توان بر اودوم و شاردا اشاره کرد. آن‌ها برای اولین بار با استفاده از شبکه‌های عصبی مصنوعی اقدام به پیش‌بینی درماندگی مالی کردند (اودوم^۴ و شاردا^۵، ۱۹۹۰). به‌منظور بررسی بهتر ادبیات موضوع در ادامه راه اودوم و شاردا در جدول شماره ۱ اقدام به بررسی برخی از مهم‌ترین پژوهش‌های این حوزه شده است. نکته مشترک در تقریباً تمامی این پژوهش‌ها وجود دو

1. Martin
2. Ravi Kumar
3. Ravi
4. Odom
5. Sharda

مرحله اساسی است؛ مرحله اول، انتخاب نسبت‌های مالی مؤثر یا همان ورودی‌های اصلی مدل است و مرحله دوم، طراحی و بهینه‌سازی ابر پارامترها^۱ و پارامترهای مدل دسته‌بندی است.

مروری بر پیشینه پژوهش

در پژوهش‌های انجام شده تا به حال ابتدا به انتخاب متغیرهای مؤثر (نسبت‌های مالی) که متناظر با انتخاب ویژگی و استخراج الگو است پرداخته شده است. بنابراین متغیرهای کلیدی انتخاب شده برای هر پژوهش متمایز بوده است. اگرچه در میان پژوهش‌ها روش غیر ریاضیاتی نیز برای انتخاب متغیرهای مؤثر کلیدی وجود دارد. به طور مثال در برخی از پژوهش‌ها با استناد بر پژوهش‌های پیشین و بدون انجام مرحله انتخاب مؤلفه‌های مؤثر اقدام به مدل‌سازی و پیش‌بینی احتمال درماندگی مالی شده است. از سوی دیگر، برای انجام این مرحله روش‌های آماری مثل آزمون خی‌دو، آزمون تی استودنت، آزمون کایمن کولموگروف، روش انتخاب مؤلفه‌های اساسی، آزمون من ویتنی و همچنین، آزمون همبستگی مورد استفاده قرار گرفته است. مرحله دوم که همان ساخت مدل دسته‌بندی است، در واقع یک مسئله دسته‌بندی دو کلاسه با ناظر یادگیری ماشین است که اغلب در مسائل درماندگی با استفاده از الگوریتم ماشین بردار پشتیبان حل شده است.

جدول ۱. پژوهش‌های پیشین انجام شده بر روی پیش‌بینی درماندگی مالی با استفاده از مدل‌های نوین یادگیری ماشین به تفکیک داخلی و خارجی

محل پژوهش	نویسندگان (سال انتشار)	مدل پیش‌بینی	داده‌های مورد بررسی	دقت‌های پیش‌بینی	توضیحات و نتایج
۲ ۳	راعی و فلاح‌پور (۱۳۸۷)	ماشین بردار پشتیبان ^۲	۸۰ شرکت بورس اوراق بهادار تهران	بین ۷۵/۷۸ تا ۸۷/۵ درصد	در این پژوهش نشان داده شد که مدل ماشین بردار پشتیبان از مدل رگرسیون لجستیک دقیق‌تر پیش‌بینی می‌کند.
	سعیدی و آقایی (۱۳۸۸)	شبکه‌های بیز ^۳	۱۴۴ شرکت بورس اوراق بهادار تهران	بین ۷۴ تا ۹۴ درصد	پژوهش آن‌ها نشان داد که شبکه‌های بیز به کمک عمل گسسته‌سازی عملکرد بهتری نسبت به شبکه‌های بیز ساده دارند.
	منصور فر، غیور و لطفی (۱۳۹۲)	ماشین بردار پشتیبان	۱۱۸ شرکت بورس اوراق بهادار تهران	بین ۵۵/۱ تا ۶۹/۳۹ درصد	پژوهش آن‌ها نشان داد که مؤلفه‌های جریان‌های نقدی شرکت به کمک ماشین بردار پشتیبان در پیش‌بینی درماندگی مالی مؤثر هستند.
	فلاح‌پور و دیگران (۲۰۱۷)	روش ترکیبی تحلیل مؤلفه‌های اساسی ^۴ ، الگوریتم ژنتیک ^۵	۱۸۰ شرکت بورس اوراق بهادار تهران	بین ۹۱/۶۷ تا ۹۷/۷۸ درصد	در این پژوهش نشان داده شد که روش انتخاب ویژگی تحلیل مؤلفه‌های اساسی بهتر از الگوریتم ژنتیک عمل می‌کند.

1. Hyper parameter
2. Support Vector Machine
3. Bayesian Network
4. Principal Component Analysis
5. Genetic Algorithm



محل پژوهش	نویسندگان (سال انتشار)	مدل پیش‌بینی	داده‌های مورد بررسی	دقت‌های پیش‌بینی	توضیحات و نتایج
		و ماشین بردار پشتیبان			
	علی اکبرلو، منصور فر و غیور (۱۳۹۹)	ماشین بردار پشتیبان، درخت تصمیم ^۱ ، شبکه عصبی مصنوعی	-	بین ۷۹/۰۱ تا ۹۷/۵۲ درصد	نتایج این پژوهش نشان داد که شاخص‌های مالی می‌توانند به خوبی درماندگی شرکت‌ها را توضیح دهند.
	نمازی و ابراهیمی (۱۳۹۹)	ماشین بردار پشتیبان و روش	۴۲۱ شرکت بورس اوراق بهادار تهران	بین ۴۰ تا ۷۸ درصد	این پژوهش به‌عنوان تنها پژوهش داخلی که دارای برچسب‌های متوازن نیست، نشان داد که متغیرهای حاکمیت شرکتی و متغیرهای کلان اقتصادی در پیش‌بینی درماندگی مالی مؤثر هستند.
	سان ^۲ و جی ^۳ (۲۰۱۲)	روش ترکیبی انتخاب مؤلفه‌های اساسی و ماشین بردار پشتیبان	شرکت‌های بازار بورس چین	بین ۶۸ تا ۹۱ درصد	پژوهش آن‌ها نشان داد که روش ترکیبی ماشین بردار پشتیبان با کرنل شعاعی همراه با انتخاب مؤلفه‌های اساسی بهتر از ماشین بردار پشتیبان به‌تنهایی عمل می‌کند.
	اردوغان ^۴ ، (۲۰۱۳)	ماشین بردار پشتیبان	۴۲ بانک در کشور ترکیه	بین ۹۰ تا ۹۸ درصد	پژوهش آن‌ها نشان داد که ماشین‌های بردار پشتیبان با کرنل گوسی توانایی خوبی در استخراج دانش داشته و می‌تواند به‌عنوان یک سیستم انظار دهنده مورد استفاده قرار گیرند.
	چو و دیگران (۲۰۱۷)	الگوریتم ژنتیک و منطق فازی ^۵	داده‌های ۶۰۰ شرکت از پایگاه داده مجله اقتصادی تایوان	-	پژوهش آن‌ها جزء معدود پژوهش‌های است که تا داده‌های ۳ سال قبل از وقوع درماندگی را در مدل دخیل کرده است و نتایج نشان داد که روش الگوریتم ژنتیک به‌خوبی می‌تواند در انتخاب متغیرهای مؤثر عمل کند.
	یو ^۶ و دیگران (۲۰۱۸)	روش ترکیبی شبکه‌های باور عمیق ^۷ و ماشین بردار پشتیبان	داده‌های نمونه از کشور آلمان و ژاپن با بیش‌تر از ۱۰۰۰ نمونه	بین ۵۱ تا ۹۳ درصد	پژوهش آنها نشان داد که روش تلفیقی آن‌ها در بررسی اعتبارسنجی مشتریان بهتر از روش ماشین بردار پشتیبان به‌تنهایی عمل می‌کند.

و
و

1. Decision Tree
2. Sun
3. Jie
4. Erdogan
5. Fuzzy logic
6. Yu
7. Deep Belief Neural Network

محل پژوهش	نویسندگان (سال انتشار)	مدل پیش‌بینی	داده‌های مورد بررسی	دقت‌های پیش‌بینی	توضیحات و نتایج
	(مالاکاوسکاس ^۱ و لاکشتوتین ^۲ (۲۰۲۱))	شبکه عصبی، درخت تصمیم، رگرسیون لجستیک ^۳	داده‌های مربوط به ۱۲ هزار کسب‌وکار کوچک و متوسط در کشورهای بالتیک (استونی، لتونی و لیتوانی)	بین ۳۸ تا ۶۵ درصد	پژوهش آن‌ها نشان داد که افزودن متغیرهای مربوط به سال‌های پیشین می‌تواند در بهبود عملکرد مدل‌های پیش‌بینی مؤثر واقع شود.
	سان و دیگران (۲۰۲۱)	روش ترکیبی ماشین بردار پشتیبان و تجزیه داده‌ها	داده‌های ۲۸۹۳ شرکت چینی از بورس شانگهای و شنزن	بین ۶۳ تا ۹۹/۴ درصد	در این پژوهش به‌جای طبقه‌بندی ۲ کلاس، وضعیت شرکت‌ها را به ۴ دسته تقسیم‌بندی کرده و نشان دادند که روش یک‌به‌یک تجزیه همراه با ماشین بردار پشتیبان بهترین عملکرد را در پیش‌بینی ارائه می‌دهد.
	سای ^۴ و دیگران (۲۰۲۱)	تلفیقی از ۳ روش پیش‌پردازش با ۵ روش دسته‌بندی از جمله شبکه‌های عصبی و ماشین بردار پشتیبان	-	-	در این پژوهش نشان داده شد که به‌جای استفاده از یک روش مشخص در پیش‌بینی درماندگی، بهتر است از تلفیق تمام روش‌های موجود و گرفتن آرای اکثریت برای یافتن پاسخ به مسئله دسته‌بندی استفاده کرد.

مأخذ: جمع‌آوری پژوهش

همان‌طور که بیان شد، تقریباً تمام پژوهش‌های انجام شده در حوزه پیش‌بینی درماندگی مالی از جمله پژوهش بیور و آلتمن، شامل دو مرحله اصلی هستند. مرحله اول که شامل انتخاب مؤلفه‌های کلیدی ورودی هست و مرحله دوم که شامل تدوین مدل پیش‌بینی است. این پژوهش نسبت به سایر پژوهش‌های داخلی و خارجی انجام شده نوآوری‌های به‌خصوصی دارد. آن چیزی که این پژوهش را از آنچه که تا به حال ذکر شد متمایز می‌سازد، تلاش بر حذف مرحله انتخاب متغیرهای کلیدی در فرایند پیش‌بینی درماندگی مالی است. در این پژوهش، روش یادگیری عمیق به‌کاررفته، به دلیل ویژگی‌های مختص به خود، می‌تواند به‌نوعی مرحله اول سایر پژوهش‌ها را به شکل دیگر در مرحله دوم بگنجانند. به طوری که با استخراج ویژگی از میان متغیرهای داده شده به آن، عملیات انتخاب متغیرهای مؤثر را به شکل خودکار انجام داده و در صورتی که تغییری تأثیر مشخصی در پیش‌بینی احتمال درماندگی نداشته باشد، آن را بدون حذف کردن، بی‌اثر می‌کند. بنابراین، دیگر نیاز نخواهد بود که در یک مرحله اولیه با استفاده از یک مدل خاص دیگری اقدام به انتخاب ورودی‌های مؤثر کرد. نوآوری دیگری که در این پژوهش وجود دارد دخیل کردن متغیرهای

1. Malakauskas
2. Lakštutienė
3. Logistic Regression
4. Tsai

تا ۲ سال قبل از وقوع درمان‌دگی در مدل پیش‌بینی است. این در حالی است که بسیاری از تحقیق‌های مشابه متغیرهای هر سال را به شکل جدا در اختیار مدل قرار داده‌اند و دقت مدل‌ها را می‌سنجند. به بیان دیگر از آن جایی که مدل به‌کاررفته در این پژوهش به‌خوبی توانایی پردازش و واکاوی متغیرهای دوبعدی را دارد، می‌تواند تأثیرات و تمایزاتی که در رفتار یک نسبت مالی در طول زمان رخ می‌دهد را نیز بررسی نماید. این در حالی است که در پژوهش راعی و فلاح‌پور (راعی، فلاح‌پور، ۱۳۸۷) مدل بر روی داده‌های نسبت‌های مالی در سال رخ‌دادن درمان‌دگی آموزش داده‌شده و سپس، از همان پارامترهای تخمین زده شده به‌عنوان ضریب متغیر پیش‌بینی همان نسبت‌ها اما در سال‌های قبل از رخ‌دادن درمان‌دگی نیز مورد استفاده قرار می‌گرفته است. به بیانی ساده‌تر، اگرچه به طور مثال نسبت بدهی‌های جاری به دارایی‌های جاری در سال t و $t-1$ ماهیت مشابهی دارند، اما برای مدل پیش‌بینی و تخمین زنده، مفهوم‌های متفاوت و رفتارهای متمایزی دارند. بنابراین، بهتر است که این‌گونه به مسئله نگاه شود که همین نسبت ذکر شده برای مدل یادگیری ماشین در زمان t یک متغیر بخصوص و در زمان $t-1$ متغیر متمایز دیگری محسوب می‌شود. در واقع، وجه تمایز این متغیر در زمان t نسبت به همین متغیر در زمان $t-1$ ، در فاصله آن‌ها نسبت به زمان وقوع درمان‌دگی است و طبیعتاً رفتار این متغیر در سال وقوع بحران با سال قبل از بحران متفاوت است. به همین سبب این انتظار وجود دارد که مدل یادگیری عمیق توسعه داده شده در این پژوهش، دقت بیش‌تری نسبت به روش‌های پیشین داشته باشد.

مسئله دسته‌بندی با ناظر

در علم یادگیری ماشین مسائل متعددی وجود دارد که برای حل آن از الگوریتم‌های متعددی استفاده می‌شود. از یک جنبه می‌توان این مسائل را به دو دسته مسائل رگرسیون و دسته‌بندی تقسیم نمود. مسائل دسته‌بندی، مسائلی هستند که در آن‌ها داده‌ها برحسب ویژگی‌هایی که دارند در دو یا چند گروه متمایز تقسیم‌بندی می‌شوند. علت آنکه این مسائل را با ناظر نام می‌برند این است که داده‌های مورد بررسی در این‌گونه مسائل، برجسبی (متغیر وابسته) دارند که به کمک آن پارامترهای مدل یادگیری ماشین را در جهت حداقل کردن خطاهای پیش‌بینی، اصلاح می‌کند. به بیانی دیگر الگوریتم یادگیری ماشین با در دست داشتن برجسب و ویژگی‌های نمونه‌های مورد بررسی (متغیرهای مستقل)، به کشف روابط میان ویژگی‌ها می‌پردازد و پارامترهای مدل موردنظر را تخمین می‌زند.

شبکه‌های عصبی پیچشی

شبکه‌های عصبی پیچشی یکی از انواع شبکه‌های عصبی عمیق و پیشرفته هستند که اولین بار برای پردازش داده‌های تصویر مورد استفاده قرار گرفتند (لیکان^۱ و دیگران، ۲۰۱۵). این شبکه‌های عصبی که در دسته روش‌های یادگیری عمیق قرار می‌گیرند به شکل بسیار قدرتمندی در تشخیص و دسته‌بندی تصاویر

عمل کرده‌اند (کریژوسکی^۱، ۲۰۱۷)، به شکلی که در یک معماری معروف از آن که به شبکه رزنت^۲ معروف است، قدرت پیش‌بینی و دسته‌بندی آن‌ها از انسان دقیق‌تر بوده و انسان را شکست داده است (ژانگ^۳ و دیگران، ۲۰۱۶).

شبکه‌های عصبی پیچشی، تنسورها^۴ (ماتریس‌های ۲ بعد و بیشتر) را به شکلی بسیار دقیق با استفاده از ماتریس‌های کوچک‌تری با نام کرنل^۵ مورد ارزیابی قرار می‌دهند. ماتریس‌های کرنل در واقع یک ماتریس کوچکی هستند که بر روی تنسورها لغزیده و عمل کانوالو^۶ کردن را انجام می‌دهند. عمل کانوالو کردن شامل یک ضرب و جمع بسیار ساده درایه به درایه در ماتریس‌ها است. بعد از عمل کانوالو شدن ماتریس اولیه، ماتریس (ها) شکل دیگری می‌گیرد که بازنمایی ای از ماتریس اولیه است. در واقع با تکرار عمل کانوالو شدن، ماتریس اولیه تبدیل به یک ماتریس یا بردار جدیدی می‌شود که درک آن برای انسان امکان‌پذیر نیست، اما دانشی در این ماتریس وجود دارد که برای ماشین (رایانه) قابل درک است. بنابراین، رایانه می‌تواند با وارد کردن این بردار یا ماتریس جدید به یک شبکه عصبی با لایه‌های اتصال متراکم به عمل دسته‌بندی بپردازد. در واقع شبکه‌های عصبی پیچشی شامل دو قسمت اساسی هستند؛ قسمت اول، فاقد نورون‌های با اتصال متراکم است و صرفاً به استخراج ویژگی از میان داده‌ها می‌پردازد و قسمت دوم، دقیقاً مشابه شبکه‌های عصبی رو به جلو با قابلیت پس انتشار است و ماتریس بازنمایی به آن‌ها به عنوان ورودی داده می‌شود. دقت به توضیحات این قسمت این نکته را در ذهن متبادر می‌کند که همان مرحله اول موجود در بسیاری از تحقیقات پیش‌بینی درماندگی مالی در مرحله کانوالو کردن شبکه‌های عصبی پیچشی به شکلی دیگر در حین فرایند آموزش شبکه رخ می‌دهد. شبکه‌های عصبی پیچشی در عملیات استخراج دانش خود هر درایه ماتریس را نسبت به درایه‌های اطراف خود بسته به شکل کرنل استفاده شده، مقایسه کرده و نورون‌های غیرمتراکم آن را تحریک می‌کند. به همین دلیل توانایی استخراج ویژگی‌هایی را دارد که شبکه‌های عصبی عادی پرسپترون چندلایه ندارند. به طور معمول برای آموزش شبکه‌های عصبی و حل مسئله دسته‌بندی دو کلاسه از تابع هزینه آنتروپی مقاطع دودویی^۷ استفاده می‌شود. این تابع هزینه با تخصیص یک احتمال به هر یک از دو دسته موجود، احتمال رخ داد برچسب‌ها را نشان می‌دهد؛ بنابراین، آن برچسبی که بیشترین احتمال رخ داد را داشته باشد، پیش‌بینی نهایی الگوریتم است. در واقع با وجود این تابع هزینه، شبکه و وزن‌های آن به شکلی بهینه می‌شود که تمام برچسب‌هایی که پاسخ درست هستند، احتمال بالاتری نسبت به پاسخ نادرست به دست بیاورند. این تابع هزینه به شکل رابطه ۲ محاسبه می‌شود.

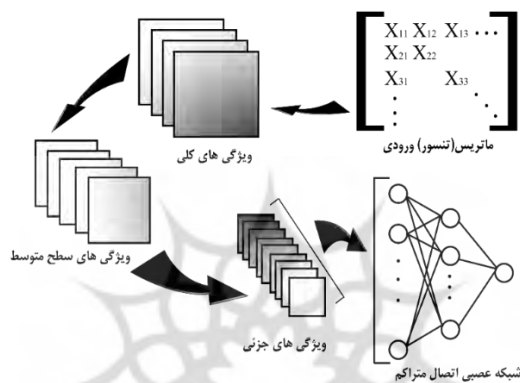
$$\log loss = \frac{1}{N} \sum_{i=1}^N -(y_i \times \log(p_i) + (1 - y_i) \times \log(1 - P_i)) \quad \text{رابطه ۲}$$

1. Krizhevsky
2. Resnet
3. Zhang
4. Tensor
5. Kernel
6. Convolve
7. Binary cross entropy



در این رابطه که مخصوص دسته‌بندی ۲ کلاسه است، p_i احتمال رخداد دسته شماره ۱ و $1 - p_i$ احتمال رخداد دسته شماره صفر می‌باشد.

به شکل کلی معماری عمومی شبکه‌های عصبی پیچشی در شکل شماره ۱ نشان داده شده است که از تنسورهای ورودی به شبکه با هر بار عبور از لایه پیچشی ویژگی‌هایی استخراج می‌شود که با افزایش تعداد این لایه‌ها ویژگی‌های استخراج شده بیشتر و جزئی‌تر می‌شود. در نهایت ویژگی‌های استخراج شده به شکل تنسورهایی که لزوماً ابعادشان با تنسور ورودی یکی نیست به دست یک شبکه عصبی پرسپترون چندلایه با نورون‌های اتصال متراکم داده می‌شوند.



شکل ۱. ساختار و معماری شبکه عصبی پیچشی
مأخذ: توضیحات پژوهشگران

روش K-fold

برای حل مسائل دسته‌بندی با ناظر به کمک تخمین مدل‌های شبکه عصبی یا به شکل کلی‌تر روش‌های یادگیری ماشین یکی از مشکلاتی که محققان با آن مواجه می‌شوند، مشکل تصادفی بودن انتخاب داده‌های آموزش و آزمون است. در حل مسائل دسته‌بندی با ناظر ممکن است طی فرایند نمونه‌گیری برای انتخاب داده‌های آزمون، داده‌هایی انتخاب شوند که برای مدل آموزش دیده بسیار دقیق عمل نمایند، در حالی که اگر نمونه تصادفی دیگری برای آزمون انتخاب می‌شد، دانش استخراج شده از داده‌های آموزش نمی‌توانست آن را پیش‌بینی نماید. به این نوع خطا، خطای تعمیم‌دهی می‌گویند، و این باعث می‌شود که تورش مدل افزایش یابد. یکی از روش‌های ارائه شده برای حل این مشکل، روش K-fold است. در این روش با توجه به اندازه کل داده‌ها، آن‌ها به K دسته تقسیم می‌شوند. سپس هر بار یک دسته کنار گذاشته شده و مدل با استفاده از سایر دسته‌ها آموزش می‌بیند و در نهایت، پارامترهای تخمین زده شده بر روی داده‌های آن دسته داده‌های کنار گذاشته شده آزمون می‌شود. این عملیات تا آن جایی انجام می‌شود که تمام دسته‌ها یک بار به عنوان داده آزمون در نظر گرفته شده و دقت و خطای تخمین بر روی آن‌ها، ذخیره شود. در این حالت مدل K بار به شکل مستقل آموزش و آزمون می‌شود. با بررسی دقت‌های به دست آمده و میانگین خطاهای حاصل شده می‌توان خطای قابل‌اتکاتری نسبت به توانایی استخراج دانش مدل به دست آورد.

آزمون علامت Wilcoxon

آزمون Wilcoxon یک آزمون علامت است. این آزمون همچون آزمون تی استیودنت که برای بررسی صفر بودن تفاوت میانگین دو نمونه است، می‌تواند مورد استفاده قرار بگیرد. اما تفاوت این آزمون با آزمون تی استیودنت این است که آزمون Wilcoxon بر روی داده‌هایی مورد استفاده قرار می‌گیرد که توزیع مشخصی ندارند. به بیانی دیگر آزمون Wilcoxon یک آزمون ناپارامتریک برای بررسی صفر بودن اختلاف میانگین دو نمونه است. آماره آزمون Wilcoxon به شرح رابطه ۳ محاسبه می‌شود.

$$w = \sum_{i=1}^{N_r} [\text{sgn}(x_{2,i} - x_{1,i}) \cdot R_i] \quad \text{رابطه ۳}$$

در رابطه ۳، $x_{1,i}$ و $x_{2,i}$ جفت عضوهای نمونه‌ای هستند که قرار است تفاوت آنها آزمون شود. N_r تعداد عضوهای نمونه‌ای مورد بررسی است. نکته بسیار مهم در محاسبه آماره آزمون Wilcoxon این است که در محاسبه تعداد اعضای نمونه آن جفت عضوهایی که برابر هستند در شمارش نمونه محاسبه نمی‌شوند. و در نهایت R_i جایگاه قرار گرفتن اختلاف جفت عضوها پس از مرتب کردن داده‌ها می‌باشد.

روش‌شناسی پژوهش


در این پژوهش با استفاده از زبان برنامه‌نویسی پایتون و کتابخانه‌های متعددی از جمله تانسورفلو^۱ برای پیاده‌سازی شبکه عصبی پیچشی استفاده شده است. داده‌های این پژوهش از سایت کدال^۲ و بورس‌ویو^۳ و شامل ۱۵۰ شرکتی است که طبق ماده ۱۴۱ قانون تجارت در مانده محسوب می‌شوند. داده‌های این شرکت‌ها با فیلتر سال‌های بین ۱۳۸۰ تا ۱۴۰۰ گردآوری شده‌اند. به منظور گردآوری ۱۵۰ نمونه از شرکت‌های غیردرمانده و جهت متعادل ساختن برجسب‌ها، به شکل تصادفی از میان سایر موارد شرکت‌هایی که در مانده نبودند، انتخاب شدند. داده‌های گردآوری شده شامل ۱۴ نسبت مالی بوده که لیست آن در جدول شماره ۲ نشان داده شده است.

جدول ۱. نسبت‌های مالی به کار رفته برای مدل‌سازی پیش‌بینی درماندگی

شماره متغیر	نام متغیر	شماره متغیر	نام متغیر
۸	نسبت جاری	۱	سود خالص به فروش
۹	نسبت آبی	۲	سود عملیاتی به فروش
۱۰	نسبت نقدینگی	۳	سود ناخالص به فروش
۱۱	نسبت بدهی	۴	سود خالص به سود ناخالصی
۱۲	نسبت مالکانه	۵	بازده دارایی‌ها (ROA)
۱۳	نسبت پوشش‌دهی	۶	بازده سرمایه (ROE)
۱۴	نسبت موجودی کالا به سرمایه در گردش	۷	نسبت دارایی‌های جاری

مأخذ: محاسبات پژوهش

بعد از گردآوری داده‌ها، هر نمونه به یک ماتریس ۳ در ۱۴ تبدیل می‌شود. از آنجایی که داده‌ها در سه مقطع زمانی $t-2$ و $t-1$ و t گردآوری شده‌اند در ۳ ردیف و ۱۴ ستون که نمایش‌دهنده زمان و نسبت‌های مالی استخراج شده است، ذخیره می‌شوند. به منظور نمایش داده‌ها می‌توان از یک نمودار حرارتی^۱ و داده‌های تغییر مقیاس داده شده استفاده کرد. به این شکل می‌توان توضیح داد که چنین مسئله‌ای می‌تواند شبیه مسئله پردازش تصویر باشد و از شبکه عصبی پیچشی برای شناسایی آن استفاده کرد. شباهت حل این مسئله دسته‌بندی با مسائل پردازش تصویر در این است که در هر دو آن‌ها الگوهایی وجود دارد که متمایز کننده آن‌ها بر حسب برجسبشان است. اما تفاوتی که این دو مسئله دارند در این است که در پردازش تصویرهای به طور مثال حیوانات، داده‌های ورودی که عکس حیوانات است برای انسان قابل درک می‌باشد. اما در مسئله پیش‌بینی درمان‌دگی مالی داده‌های ورودی در قالب تصویر برای انسان قابل درک نیست. اما به هر شکل، قابل درک بودن این ورودی‌ها برای انسان موضوع حائز اهمیتی نیست. نکته‌ای که بسیار مهم است، توان ماشین در استخراج دانش و الگوهای موجود در تصویر حاصل شده از داده‌های ورودی از جنس نسبت‌های مالی داده شده می‌باشد. شکل شماره ۲ یک نمونه از داده با برجسب یک یعنی درمانده و یک نمونه داده با برجسب صفر یعنی غیردرمانده را نمایش می‌دهد.



شکل ۲. نمودار حرارتی از یک نمونه از داده‌های به کار رفته در این پژوهش از هر یک از کلاس‌های صفر و یک
مأخذ: داده‌های پژوهش

از آنجاکه شبکه‌های عصبی پیچشی توان پردازش داده‌ها را در ۲ و ۳ بعد دارند نیاز به تغییر شکل دادن ماتریس وجود ندارد. تنها کار لازم به منظور افزایش توان شبکه در همگرا شدن بهتر، تغییر مقیاس دادن داده‌ها و استانداردسازی آن‌ها است. بدین منظور در این پژوهش از کتابخانه Sikit-learn استفاده شده است. در ادامه برای جلوگیری از مشکلات تورش مدل ناشی از نمونه‌گیری، از روش K-fold استفاده شده است، و داده‌ها به ۵ قسمت مساوی تقسیم میشوند. به همین دلیل مدل موردنظر ۵ بار آموزش دیده،

ارزیابی شده و نتایجش ثبت می‌شود. هر بار که شبکه آموزش می‌بیند با ۲۴۰ عدد از نمونه‌ها (معادل ۸۰ درصد داده‌ها) مواجه شده و با ۶۰ نمونه (معادل ۲۰ درصد داده‌ها) مورد ارزیابی قرار می‌گیرد. پس از آماده‌سازی داده‌ها نوبت به بهینه‌کردن ابر پارامترهای مدل می‌رسد. از آنجایی که شبکه‌های عصبی پیچشی به راحتی دچار بیش‌برازش بر روی داده‌های آموزش می‌شوند، این مرحله بسیار مهم است. از طرفی عمیق کردن بیش از حد شبکه (افزودن بر تعداد لایه‌ها) موجب محو شدن تابع گرادینان^۱ می‌شود. در این صورت دیگر وزن‌های شبکه آن قدر کند اصلاح می‌شوند که آموزش عملاً امکان‌پذیر نخواهد بود. از طرف دیگر، شبکه عصبی با تعداد لایه کم، توان پردازش و استخراج دانش به اندازه کافی از میان داده‌ها را نخواهد داشت؛ بنابراین، از یک شبکه با دو لایه پیچشی که لایه اول دارای کرنل ۳ در ۳ و لایه پیچشی دوم دارای کرنل ۲ در ۲ بوده است استفاده شد. پس از لایه‌های پیچشی، شبکه به یک لایه با اتصالات متراکم ۳ و ۵ نورون متصل شده و بعد از آن به لایه خروجی با ۲ نورون (مسئله ۲ کلاسه) خروجی متصل شده است. به منظور جلوگیری از بیش‌برازش و اتکای بیش از حد بر روی یک نورون خاص از لایه‌های حذف تصادفی نورون‌ها که توسط سریویستا و دیگران معرفی شده است، نیز استفاده شده است (سریویستا^۲ و دیگران، ۲۰۱۴). در حل مسائل دسته‌بندی دو کلاسه به طور معمول از تابع هزینه آنتروپی مقاطع دودویی استفاده می‌شود. نتایج پژوهش‌های متعدد نشان می‌دهد این تابع هزینه با توجه به اختصاص دادن احتمال به هر یک از کلاس‌ها می‌تواند بهتر از سایر توابع هزینه در مسائل دو کلاسه عمل کند. یکی دیگر از ابر پارامترهای مهم در آموزش شبکه‌های عصبی، توابع فعال‌ساز است. برای آن که در این پژوهش روابط غیرخطی به خوبی واکاوی شوند و در عین حال از مشکلاتی از جمله عدم همگرا شدن تابع گرادینان و محو شدن تابع گرادینان جلوگیری شود از تابع فعال‌ساز ریلو^۳ استفاده شده است. در نهایت، به منظور بهینه‌سازی شبکه از بهینه‌ساز آدام استفاده شده است که از بهینه‌سازهای موفق گرادینان کاهشی محسوب می‌شود.

باتوجه به این که در این پژوهش یک الگوریتم نوین برای پیش‌بینی در ماندگی ارائه شده است، نیاز به مقایسه آن با روش‌های انجام شده در ادبیات موضوع وجود دارد. بدین منظور از دو الگوریتم رگرسیون لجستیک و ماشین بردار پشتیبان به عنوان مدل‌های پایه استفاده شده است. همانطور که در جدول ۱ نشان داده شد، این دو الگوریتم در بسیاری از پژوهش‌های انجام شده داخلی و خارجی مورد استفاده قرار گرفته است. بنابراین، مقایسه مدل توسعه‌داده شده در این پژوهش با آن‌ها می‌تواند روش مناسبی برای ارزیابی باشد. در نهایت، با استفاده از آزمون Wilcoxon معنی‌داری اختلاف دقت پیش‌بینی‌های ارائه شده توسط مدل‌های استفاده شده در این پژوهش، مورد ارزیابی قرار گرفته است.

تجزیه و تحلیل داده‌ها و آزمون فرضیه‌ها

پس از بهینه‌سازی و آموزش مدل‌های به‌کاررفته در این پژوهش، تمامی مدل‌ها مورد ارزیابی قرار گرفتند. جدول شماره ۳ نشان‌دهنده دقت پیش‌بینی مدل شبکه عصبی پیچشی توسعه داده شده و پیشنهاد

1. Vanishing gradient
2. Srivastava
3. ReLU

شده در این پژوهش است. همان‌طور که در این جدول نشان داده شده است دقت مدل در پیش‌بینی داده‌های آزمون بر روی نمونه فرعی ۳ از سایر نمونه‌های فرعی کمتر است. این می‌تواند دلایل متعددی از جمله نوفه^۱ داده‌های این نمونه خاص باشد. از طرفی دیگر مدل پیش‌بینی پیشنهاد شده در پیش‌بینی نمونه فرعی شماره ۱ از سایر نمونه‌های فرعی بهتر عمل کرده است و در کل این مدل دقتی بین ۹۵/۵ تا ۹۷/۴۲ درصد را بر روی داده‌های آزمون به دست آورده است.

جدول ۲. نتایج دقت پیش‌بینی مدل دسته‌بندی دو کلاسه شبکه عصبی پیچشی بر روی کل داده‌ها

شبکه عصبی پیچشی					نام گروه
نمونه فرعی (۵)	نمونه فرعی (۴)	نمونه فرعی (۳)	نمونه فرعی (۲)	نمونه فرعی (۱)	
۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	درمانده مالی
۹۷/۲۹	۹۷/۵۱	۹۵/۱۴	۹۶/۰۰	۹۷/۲۹	
۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	غیر درمانده مالی
۹۷/۵۱	۹۷/۵۸	۹۵/۸۶	۹۶/۷۷	۹۷/۵۶	
۳۰۰	۳۰۰	۳۰۰	۳۰۰	۳۰۰	کل
۹۷/۴۰	۹۷/۵۴	۹۵/۵۰	۹۶/۳۸	۹۷/۴۲	

مأخذ: محاسبات پژوهش

همان‌طور که گفته شد به‌منظور سنجش بهتر عملکرد پیش‌بینی مدل پیشنهادی از دو مدل مبنا نیز در این پژوهش استفاده شده است. نتایج پیش‌بینی این دو مدل مبنا در جدول شماره ۴ نشان داده شده است. نتایج پیش‌بینی هر دو مدل در پیش‌بینی نمونه فرعی شماره ۳ همچون مدل شبکه عصبی پیچشی ضعیف‌تر از سایر نمونه‌های فرعی است. این نتیجه نشان می‌دهد که نمونه شماره ۳ با احتمال بالایی دارای مشاهده‌های غیرمتعارف یا اصطلاحاً حاوی نوفه است. اما مدل رگرسیون لجستیک در پیش‌بینی نمونه فرعی شماره ۴ و مدل ماشین بردار پشتیبان در پیش‌بینی نمونه فرعی شماره ۱ بهترین دقت را کسب کرده‌اند. در نهایت، با مشاهده نتایج به‌دست‌آمده از هر سه مدل و اطلاعات موجود در جداول ۳ و ۴، می‌توان این نتیجه را گرفت که مدل شبکه عصبی پیچشی در پیش‌بینی تمامی این ۵ نمونه فرعی و همچنین، در پیش‌بینی هریک از انواع برچسب‌های دوگانه (شرکت‌های درمانده مالی و غیر درمانده مالی) نسبت به دو مدل مبنا بهتر عمل کرده است.

جدول ۳. نتایج دقت پیش‌بینی های انجام شده توسط مدل های پایه

نام گروه	رگرسیون لجستیک					ماشین بردار پشتیبان				
	نمونه فرعی (۱)	نمونه فرعی (۲)	نمونه فرعی (۳)	نمونه فرعی (۴)	نمونه فرعی (۵)	نمونه فرعی (۱)	نمونه فرعی (۲)	نمونه فرعی (۳)	نمونه فرعی (۴)	نمونه فرعی (۵)
درمانده مالی	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰
	۸۸/۱۲	۸۸/۶۱	۸۷/۳۳	۸۹/۱۹	۸۸/۶۹	۹۰/۲۱	۸۹/۸۸	۸۷/۱۳	۸۹/۳۶	۸۸/۷۸
غیر درمانده مالی	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰	۱۵۰
	۸۷/۹۵	۸۹/۰۴	۸۶/۴۳	۸۹/۲۶	۸۸/۶۹	۹۰/۱۳	۸۸/۹۶	۸۶/۲۷	۸۹/۸۲	۸۷/۹۶
کل	۳۰۰	۳۰۰	۳۰۰	۳۰۰	۳۰۰	۳۰۰	۳۰۰	۳۰۰	۳۰۰	۳۰۰
	۸۸/۰۳	۸۸/۸۲	۸۶/۸۸	۸۹/۲۲	۸۸/۶۹	۹۰/۱۷	۸۹/۴۲	۸۶/۷۰	۸۹/۵۹	۸۸/۳۷

مأخذ: محاسبات پژوهش

در مرحله آخر این پژوهش به منظور بررسی این که اختلاف دقت های به دست آمده میان دو مدل مبنا و مدل شبکه عصبی پیچشی غیر صفر است یا خیر، یا به بیانی دیگر اختلاف دقت های پیش‌بینی مدل های مختلف معنی دار است یا نه، از آزمون Wilcoxon استفاده شده است. آماره آزمون Wilcoxon و مقدار احتمال آن نشان می‌دهد که اختلاف دقت هر دو مدل مبنا با مدل شبکه عصبی پیچشی در سطح اطمینان ۹۵ درصد، معنی دار و غیر صفر می‌باشد. جدول شماره ۵ نشان‌دهنده نتایج آزمون Wilcoxon می‌باشد.

جدول ۴. نتایج آزمون علامت برای آزمون اختلاف دقت پیش‌بینی ها

آزمون Wilcoxon	رگرسیون لجستیک	ماشین بردار پشتیبان
شبکه عصبی پیچشی	آماره آزمون: ۱۸۰/۰ احتمال: ۰/۰۱۱۲	آماره آزمون: ۲۸۷/۰ احتمال: ۰/۰۴۷۷

مأخذ: محاسبات پژوهش

نتیجه گیری و بحث

در علم مالی همواره مسائل پیش‌بینی از دسته مسائل مهم و درعین حال چالش برانگیز بوده است. نکته مهم این است که یک پیش‌بینی قابل اتکا می‌تواند نتایج مثبت متعددی را برای تمامی ذی‌نفعان یک شرکت به ارمغان بیاورد. به همین دلیل سالانه مقالات بسیاری در حوزه پیش‌بینی در مالی به چاپ می‌رسد که تلاش آن‌ها افزایش دقت پیش‌بینی‌هایشان است. در این پژوهش، ابتدا پیشینه موضوع درماندگی از سال ۱۹۶۶ میلادی مورد بررسی قرار گرفت و در اساس به نحوه تحول ادبیات پیش‌بینی درماندگی مالی و ورود مدل های نوین یادگیری ماشین به این عرصه اشاره شد. علاوه بر آن تعدادی از محدودیت‌های مدل‌های کلاسیک نسبت به مدل‌های امروزی نیز مورد بررسی قرار گرفت. به نظر می‌رسد که با وجود رشد چشمگیر پایگاه‌های داده و فناوری مرتبط با جمع‌آوری و ذخیره داده، وقت آن رسیده است که یک تحول دیگر در

عرضه مدل‌های پیش‌بینی درماندگی رخ بدهد. در این تحول به‌جای استفاده از مدل‌های کلاسیک یادگیری ماشین، محققان و تمام کسانی که پیش‌بینی درماندگی برایشان اهمیت دارد می‌توانند از مدل‌های یادگیری عمیق همچون شبکه‌های عصبی پیچشی استفاده کنند. به نظر می‌رسد که موفقیت این دسته از مدل‌های یادگیری ماشین وامدار قدرت بالای واکاوی آن‌ها و توان بالای آن‌ها در شناسایی الگو میان متغیرها است. از طرفی دیگر، داده‌های نسبت‌های مالی در طول زمان همچون داده‌های استفاده شده در پردازش تصویر دو بعد داشته و در ماتریس‌های ۲ بعدی قابل نمایش هستند. همچنین تمایزات میان روابط متغیرها در بعد زمان به خودی خود می‌تواند یک نشانه بسیار قدرتمند برای پیش‌بینی درماندگی مالی باشد. بنابراین زمینه برای استفاده از مدل‌های یادگیری عمیق مخصوصاً شبکه‌های عصبی پیچشی را فراهم می‌کنند. در این پژوهش که یک پژوهش موردی بر روی شرکت‌های بازار بورس تهران است، نتایج نشان داد که این اثر واکاوی و استخراج دانش می‌تواند از مدل ماشین بردار پشتیبان و رگرسیون لجستیک که مدل‌های بسیار پرکاربردی تا به حال در این موضوع بوده‌اند، بهتر عمل کند (نمازی و ابراهیمی، ۱۳۹۹) (مالاکاوسکاس^۱ و لاکستوتین^۲، ۲۰۲۱). همچنین، این پژوهش نشان داد که استفاده از پارامترهای متمایز برای تعریف رفتار یک نسبت مالی در طول زمان بهتر از حالتی عمل می‌کند که مدل بر روی یک سال مشخص آموزش داده شود و بعد از همان پارامترهای تخمین زده شده برای همان متغیر اما در سال‌های دیگر استفاده شود. نتایج آزمون Wilcoxon نشان داد که مدل توسعه داده شده مبتنی بر یادگیری عمیق به شکل معنی‌داری در سطح اطمینان ۹۵ درصد بهتر از مدل‌های پایه عمل کرده و فرض صفر این پژوهش را رد می‌کند. این در حالی است که علاوه بر این که مدل‌های یادگیری عمیق دقت بالاتری را کسب کرده است، یک مرحله چالش‌برانگیز را که در روش‌های پیشین وجود داشت، به دلیل قدرتش در استخراج ویژگی‌های متعدد از میان داده‌ها، به شکلی حذف کرده‌است. بنابراین، دیگر نیاز نخواهد بود که محققان با مشکلاتی از جمله انتخاب متغیرهای کلیدی و رفع اثرهای همبستگی میان ویژگی‌ها دست‌وپنجه نرم کنند. در نهایت، یکی از نکاتی که مدل‌های یادگیری عمیق را از سایر مدل‌های یادگیری ماشین متمایز می‌سازد افزایش توان پردازش آن‌ها در مواجهه با تعداد بیشتر داده و تعداد بیشتر ویژگی است؛ بنابراین پیشنهاد می‌شود که از مدل استفاده شده در این پژوهش بر روی نسبت‌های مالی و ویژگی‌های بیشتری در پژوهش‌های آینده استفاده شود. از آنجاکه مدل‌های یادگیری عمیق با در دست داشتن داده‌های وسیع‌تر و بیشتر می‌توانند بهتر به پاسخ جهان‌شمول دست یابند، از محدودیت‌های این پژوهش می‌توان بر کمبود موردهای درمانده، کمبود داده‌های مربوط به ویژگی‌ها و کمبود تعداد شرکت‌هایی که داده‌هایشان در دسترس است، اشاره کرد. از طرفی دیگر، از آنجاکه در این پژوهش از روش k -fold برای انتخاب نمونه‌ها استفاده شده است، نتایج دقت به دست آمده قابلیت تعمیم داشته و نتایج با مشکل تعمیم‌پذیری مواجهه نیستند. در نهایت، پیشنهاد می‌شود در حین مدل‌سازی رفتار داده‌های صورت‌های مالی به جهت پیش‌بینی

1. Malakauskas
2. Lakštutienė

درماندگی مالی، از پارامترهای متمایز برای مدل سازی نسبت‌های مالی در طول زمان استفاده شود. بدین شکل، قدرت واکاوی مدل، همان‌طور که در این پژوهش نشان داده شد، افزایش می‌یابد.

ملاحظات اخلاقی

حامی مالی: مقاله حامی مالی ندارد.
مشارکت نویسندگان: تمام نویسندگان در آماده‌سازی مقاله مشارکت داشته‌اند.
تعارض منافع: بنا بر اظهار نویسندگان در این مقاله هیچ‌گونه تعارض منافی وجود ندارد.
تعهد کپی‌رایت: طبق تعهد نویسندگان حق کپی‌رایت رعایت شده‌است.



References

- Aliakbarlou, A., Mansourfar, G., & Ghayour, F. (2020). Comparing the Identifying Criteria for Financially Distressed Companies using Logistic Regression and Artificial Intelligence Methods. *Financial Management Perspective*, 10(29), 147-166. <https://doi.org/10.52547/jfmp.10.29.147> (In Persian)
- Altman, Edward I. "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy." *The Journal of Finance* 23, no. 4 (1968): 589-609. <https://doi.org/10.2307/2978933>. <http://www.jstor.org/stable/2978933>.
- Beaver, William H. "Financial Ratios as Predictors of Failure." *Journal of Accounting Research* 4 (1966): 71-111. <https://doi.org/10.2307/2490171>. <http://www.jstor.org/stable/2490171>.
- Blum, Marc. "Failing Company Discriminant Analysis." *Journal of Accounting Research* 12, no. 1 (1974): 1-15. <https://doi.org/10.2307/2490525>. <http://www.jstor.org/stable/2490525>.
- Chou, Chih-Hsun, Su-Chen Hsieh, and Chui-Jie Qiu. "Hybrid Genetic Algorithm and Fuzzy Clustering for Bankruptcy Prediction." *Applied Soft Computing* 56 (2017/07/01/ 2017): 298-316. <https://doi.org/https://doi.org/10.1016/j.asoc.2017.03.014>. <https://www.sciencedirect.com/science/article/pii/S1568494617301370>.
- Deakin, Edward B. "A Discriminant Analysis of Predictors of Business Failure." *Journal of Accounting Research* 10, no.1. 79-167: (1972). <https://doi.org/10.2307/2490225>. <http://www.jstor.org/stable/2490225>.
- Erdogan, Birsan Eyyi. "Prediction of Bankruptcy Using Support Vector Machines: An Application to Bank Bankruptcy." *Journal of Statistical Computation and Simulation* 83, no. 8. 55-1543: (2013). <https://doi.org/10.1080/00949655.2012.666550>.
- Fallahpour, S., Norouzian Lakvan, E., & Hendijani Zadeh, M. (2017). Use of Combined Approach of Support Vector Machine and Feature Selection for Financial Distress Prediction of Listed Companies in Tehran Stock Exchange Market. *Financial Research Journal*, 19(1), 139-156. <https://doi.org/10.22059/jfr.2015.52758> (In Persian)
- Foster, Gladys Parker. "The Endogeneity of Money and Keynes's General Theory." *Journal of Economic Issues* 20, no. 4. 68-953: (1986 01/12/1986). <https://doi.org/10.1080/00213624.1986.11504570>.
- Gordon, M. J. "Towards a Theory of Financial Distress." *The Journal of Finance* 26, no. 2 (1971): 347-56. <https://doi.org/10.2307/2326050>. <http://www.jstor.org/stable/2326050>.
- He, K., X. Zhang, S. Ren, and J. Sun. "Deep Residual Learning for Image Recognition." Paper presented at the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27-30 June 2016 2016.
- Huang, Yu-Pei, and Meng-Feng Yen. "A New Perspective of Performance Comparison among Machine Learning Algorithms for Financial Distress Prediction." *Applied Soft Computing* 83 (2019/10/01/ 2019): 105663. <https://doi.org/https://doi.org/10.1016/j.asoc.2019.105663>. <https://www.sciencedirect.com/science/article/pii/S1568494619304430>.

Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet Classification with Deep Convolutional Neural Networks." *Commun. ACM* 60, no. 6 (2017): 84–90. <https://doi.org/10.1145/3065386>.

LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. "Deep Learning." *Nature* 521, no. 7553 (2015/05/01 2015): 436-44. <https://doi.org/10.1038/nature14539>.

Malakauskas, Aidan, and Aušrinė Lakštutienė. "Financial Distress Prediction for Small and Medium Enterprises Using Machine Learning Techniques." *Engineering Economics* 32, no. 1 (2021/02/26 2021): 4-14. <https://doi.org/10.5755/j01.ee.32.1.27382>. <http://dx.doi.org/10.5755/j01.ee.32.1.27382>.

Mansourfar, g., ghayour, f., & lotfi, b. (2015). The Ability of Support Vector Machine (SVM) in Financial Distress Prediction. *Empirical Research in Accounting*, 5(3), 177-195. <https://doi.org/10.22051/jera.2015.646> (In Persian)

Martin, Daniel. "Early Warning of Bank Failure: A Logit Regression Approach." *Journal of Banking & Finance* 1, no. 3 (1977/11/01/ 1977): 249-76. [https://doi.org/https://doi.org/10.1016/0378-4266\(77\)90022-X](https://doi.org/https://doi.org/10.1016/0378-4266(77)90022-X). <https://www.sciencedirect.com/science/article/pii/037842667790022X>.

Namazi, M., & Ebrahimi, S. (2021). Financial Distress Prediction of the Listed Companies on Tehran Stock Exchange (TSE) and Iran Fara Burse (IFB) Using Support Vector Machine. *Financial Management Strategy*, 9(1), 115-132. <https://doi.org/10.22051/jfm.2020.25973.2077> (In Persian).

Odom, M. D., and R. Sharda. "A Neural Network Model for Bankruptcy Prediction." Paper presented at the 1990 IJCNN International Joint Conference on Neural Networks, 17-21 June 1990 1990.

Raei, R, Fallahpour, S. Support Vector Machines Application in Financial Distress Prediction of Companies Using Financial Ratios. (2009). *Accounting and Auditing Review*, 15(4). https://acctgrev.ut.ac.ir/article_27750.html (In Persian).

Ravi Kumar, P., and V. Ravi. "Bankruptcy Prediction in Banks and Firms Via Statistical and Intelligent Techniques - a Review." *European Journal of Operational Research* 180, no. 1 (2007): 1-28. <https://EconPapers.repec.org/RePEc:eee:ejores:v:180:y:2007:i:1:p:1-28>.

Rey, Denise, and Markus Neuhäuser. "Wilcoxon-Signed-Rank Test." In *International Encyclopedia of Statistical Science*, edited by Miodrag Lovric, 1658-59. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011.

Saeedi, A., & Aghaie, A. (2009). Predicting Financial Distress of firms Listed in Tehran Stock Exchange Using Bayesian networks. *Accounting and Auditing Review*, 16(2). https://acctgrev.ut.ac.ir/article_20001.html (In Persian)

Srivastava, Nitish, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. "Dropout: A Simple Way to Prevent Neural Networks from Overfitting." *Journal of Machine Learning Research* 15 (06/01 2014): 1929-58.

Sun, Jie, Hamido Fujita, Yujiao Zheng, and Wenguo Ai. "Multi-Class Financial Distress Prediction Based on Support Vector Machines Integrated with the Decomposition and Fusion Methods." *Information Sciences* 559 (2021/06/01/ 2021): 153-70.

<https://doi.org/https://doi.org/10.1016/j.ins.2021.01.059>.

<https://www.sciencedirect.com/science/article/pii/S0020025521000979>.

Sun, Jie, and Hui Li. "Financial Distress Prediction Using Support Vector Machines: Ensemble Vs. Individual." *Applied Soft Computing* 12, no. 8 (2012/08/01/ 2012): 2254-65. <https://doi.org/https://doi.org/10.1016/j.asoc.2012.03.028>.

<https://www.sciencedirect.com/science/article/pii/S1568494612001263>.

Taj mazinani, M., Fallahpour, S., & Bajalan, S. (2015). The Use of Feature Selection Method (HARC) in Predicting Financial Distress in Tehran Stock Exchange. *Financial Management Strategy*, 3(2), 77-106. <https://doi.org/10.22051/jfm.2015.2169> (In Persian)

Tsai, C.-F., Sue, K.-L., Hu, Y.-H., & Chiu, A. (2021). Combining feature selection, instance selection, and ensemble classification techniques for improved financial distress prediction. *Journal of Business Research*, 130, 200-209. <https://doi.org/https://doi.org/10.1016/j.jbusres.2021.03.018>

Ward, Terry J., and Benjamin P. Foster. "A Note on Selecting a Response Measure for Financial Distress." *Journal of Business Finance & Accounting* 24 (1997): 869-79.

Whitaker, Richard B. "The Early Stages of Financial Distress." *Journal of Economics and Finance* 23, no. 2 (1999/06/01 1999): 123-32. <https://doi.org/10.1007/BF02745946>.

Yu, Lean, Rongtian Zhou, Ling Tang, and Rongda Chen. "A Dbn-Based Resampling Svm Ensemble Learning Paradigm for Credit Classification with Imbalanced Data." *Applied Soft Computing* 69 (2018/08/01/ 2018): 192-202. <https://doi.org/https://doi.org/10.1016/j.asoc.2018.04.049>.

<https://www.sciencedirect.com/science/article/pii/S1568494618302400>.

Zmijewski, Mark E. "Methodological Issues Related to the Estimation of Financial Distress Prediction Models." *Journal of Accounting Research* 22 (1984): 59-82. <https://doi.org/10.2307/2490859>. <http://www.jstor.org/stable/2490859>.

COPYRIGHTS



This license allows others to download the works and share them with others as long as they credit them, but they can't change them in any way or use them commercially.