

بررسی برتری مدل هیبریدی نسبت به سایر مدل‌ها در فرایند اعتبارسنجی بانک‌های کشور (مورد مطالعاتی برخی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران)

مصطفی هاشمی تیله‌نوئی^۱

صبا حسین‌زاده^۲

تاریخ دریافت: ۱۳۹۸/۱۲/۱۳

تاریخ پذیرش: ۱۳۹۹/۰۳/۳۱

چکیده

ارزیابی ریسک اعتباری یک بخش ناگسستنی از فرآیند اعطای وام می‌باشد. اهمیت اعتبارسنجی اخیراً به‌خاطر بحران مالی و کفایت سرمایه بانک‌ها افزایش یافته است. هدف از این پژوهش آزمون یک روش جدید و صحیح‌تر برای برآورد امتیاز اعتباری شرکت‌ها می‌باشد. بنابر روش‌های آماری سنتی و تکنیک‌های هوش مصنوعی (AI)، این پژوهش به پیروی از لی و همکاران، ۲۰۱۶ به آزمون مدل هیبریدی می‌پردازد که این مدل تلفیقی از مدل رگرسیون لجستیک و شبکه‌های عصبی مصنوعی (ANN) می‌باشد. جامعه آماری تحقیق حاضر شرکت‌های تولیدی پذیرفته شده در بورس اوراق بهادار تهران طی سال‌های ۱۳۸۹ تا ۱۳۹۵ می‌باشد. روش نمونه‌گیری به روش حذف سیستماتیک بوده که باتوجه به در نظر گرفتن معیارها تعداد ۹۰ شرکت تولیدی به‌عنوان نمونه پژوهش انتخاب شدند. نتایج تحقیق نشان می‌دهند که مدل هیبریدی نسبت به مدل‌های رگرسیون لجستیک و شبکه‌های عصبی مصنوعی از اعتبار بالاتری در سنجش ریسک اعتباری شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران برخوردار است.

کلید واژه: ریسک اعتباری، مدل هیبریدی، مدل رگرسیون لجستیک، مدل شبکه‌های عصبی مصنوعی

طبقه‌بندی JEL: G32, G33

^۱ استادیار گروه مدیریت، واحد تهران شرق، دانشگاه آزاد اسلامی، تهران، ایران (نویسنده مسئول)
mostafahashemi82@gmail.com

^۲ دانش آموخته کارشناسی‌ارشد مدیریت مالی، گروه مدیریت، واحد تهران شرق، دانشگاه آزاد اسلامی، تهران، ایران
sabahossinzade@ymail.com

مقدمه

ریسک اعتباری از این واقعیت ریشه می‌گیرد که طرف قرارداد نتواند یا نخواهد تعهدات خود را انجام دهد به شیوه سنتی تأثیر این ریسک با هزینه ناشی از نکول طرف قرارداد سنجیده می‌شود. زیان‌های ناشی از ریسک اعتباری ممکن است پیش از وقوع از جانب طرف قرارداد ایجاد شود بنابراین ریسک اعتباری را می‌توان به‌عنوان زیانی محتمل تعریف کرد که در اثر یک رویداد اعتباری اتفاق می‌افتد صداقت گردد، تحت عنوان عامل ریسک در نظر گرفته می‌شود. بانک‌ها در طول حیات خود با ریسک‌های مختلفی از جمله ریسک نقدینگی، اعتباری، تجاری، مالی، عدم توانایی در پرداخت، نوسانات نرخ ارز، نرخ بهره و تورم روبرو هستند. از میان آنها چهار نوع ریسک اعتباری، ریسک عملیاتی، ریسک بازار و ریسک نقدینگی بیشترین لطمه را بر پیکره بانک‌ها وارد می‌کنند. در بین این چهار نوع ریسک، ریسک اعتباری و ریسک نقدینگی جایگاه ویژه‌ای دارد، چرا که به اولین و مهم‌ترین نقش بانک در بازارهای مالی یعنی گردآوری سپرده و اعطای وام اشاره می‌کند. کاهش حاشیه سود بانک‌ها عمدتاً ناشی از عدم کارایی در مدیریت اعتباری و نقدینگی بوده و بانک‌ها را متحمل فشارهایی جهت کاهش هزینه‌ها می‌نماید (شیرین‌بخش و همکاران، ۱۳۹۰: ۱۱۲). مطالعات گذشته نشان دادند که روش‌های بسیاری می‌توانند در ارزیابی ریسک اعتباری به کار برده شوند. این روش‌ها می‌توانند به دو روش سنتی و روش‌های جدید هوش مصنوعی طبقه‌بندی شوند (لی و همکاران^۱، ۲۰۱۶: ۳۴۳). روش‌های آماری اولین و مکررترین روش‌ها در ارزیابی اعتباری یا ریسک اعتباری می‌باشند (لی و همکاران، ۲۰۱۶: ۳۴۳). بعضی از محققان از روش‌های آماری برای ساختن یک مدل ریسک اعتباری استفاده کردند (مایرز و فورگی^۲، ۱۹۶۳: ۸۰۱؛ آلمن^۳، ۱۹۶۸: ۵۹۰؛ ایورت^۴، ۱۹۶۸: ۸۹۱؛ اورگلر^۵، ۱۹۷۰: ۴۳۷؛ ویگینتون^۶، ۱۹۸۰: ۷۵۸؛ باناسیک، بایس، هافمن و لا^۷، ۱۹۸۹: ۵؛ استینیکرس و گووالتس^۸، ۱۹۸۹: ۳۱؛ کروک و توماس^۹، ۲۰۰۱: ۹۹۸؛ آلمن و ساباتو^{۱۰}، ۲۰۰۷: ۳۴۲). با توسعه تکنیک‌های اطلاعاتی و محاسباتی، اخیراً مدل‌های ریسک اعتباری دقیق‌تری بر پایه روش‌های هوش پیشرفته توسعه پیدا کردند که بیشتر قادرند تا توابع پیچیده یا غیرخطی را

¹ Li et al.,² Myers & Forgi³ Altman⁴ Ewert⁵ Orgler⁶ Wiginton⁷ Boyes, Hoffman & Low⁸ Steenackers & Goovaerts⁹ Banasik, Crook & Thomas¹⁰ Altman & Sabato

مدل‌سازی کنند (لی و همکاران، ۲۰۱۶:۳۴۳). مدل‌سازی ریسک اعتباری، یکی از موضوعات اصلی حسابداری و مالی می‌باشد که فن‌آوری‌های هوش مصنوعی در آن با موفقیت به‌کار گرفته شده‌اند (وست^۱، ۲۰۰۰:۱۳۳؛ آنجلینی، دی تولو و رولی^۲، ۲۰۰۸:۷۴۰؛ سای و وو^۳، ۲۰۰۸:۲۶۴۰). در سال‌های گذشته، مدل‌های پیش‌بینی هیبریدی، که ترکیبی از روش‌های آماری سنتی و فن‌آوری‌های هوش مصنوعی می‌باشند برای توانایی پیش‌بینی بهتر از هر یک از دو جزء پیشنهاد شدند (لی و همکاران، ۲۰۱۶:۳۴۴). برای مثال، در مهندسی محیط زیست، شافر^۴ (۲۰۰۸:۱۰۳) نشان داد که صحت پیش‌بینی مدل رگرسیون لجستیک پائین‌تر از مدل هیبریدی ANN/LOGISTIC می‌باشد. لین^۵ (۲۰۰۹:۸۳۴۰) نتایج مشابهی را هنگام پژوهش بر روی بانک‌هایی که از نظر مالی درمانده بودند، به‌دست آورد. در آن زمان گفته می‌شد که شبکه‌های عصبی ممکن نیست به ثبات تکنیک‌های آماری استاندارد برسد. و مدل‌های هیبریدی در کاربردهای مشخص ممکن است ارزشمندتر باشد (پالیوال و کومار^۶، ۲۰۰۹:۱۱). حجم مطالعات گذشته در مدل‌های امتیازدهی اعتباری هم بر روی روش‌های آماری سنتی و هم روی فن‌آوری‌های هوش مصنوعی تمرکز دارند و شواهد کمی در مورد مدل‌های ریسک اعتباری هیبریدی در ادبیات وجود دارد (لی و همکاران، ۲۰۱۶:۳۴۴). هدف این پژوهش این است تا یک مدل ریسک اعتباری هیبریدی جدید (مدل هیبریدی ANN/LOGISTIC) که ANN^۷ را با روش رگرسیون لجستیک در هم می‌آمیزد را برای وام‌دهی به شرکت‌های تولیدی پذیرفته شده در بورس اوراق بهادار تهران پیشنهاد دهد. بنابراین سؤال اصلی پژوهش این است که آیا عملکرد مدل‌های ریسک اعتباری مبتنی بر فن‌آوری هوش مصنوعی می‌تواند به‌وسیله ترکیب آنها با روش‌های آماری سنتی بهبود یابد.

¹ West

² Angelini, di Tollo & Roli

³ Tsai & Wu

⁴ Schafer

⁵ Lin

⁶ Paliwal & Kumar

⁷ Artificial Neural Network

۱. مروری بر پیشینه پژوهش

مفهوم ریسک اعتباری

ارزیابی ریسک اعتباری یک روش بالقوه پیش‌بینی ریسک متناظر با یک پرتفوی اعتباری می‌باشد مدل‌های مبتنی بر این روش می‌توانند به‌وسیله مؤسسات مالی برای ارزیابی ریسک پرتفوی‌های اعتباری مورد استفاده قرار گیرند. آنالیز ریسک اعتباری یک موضوع مهم در مدیریت ریسک مالی می‌باشد و تمرکز عمده صنعت بانکداری و مالی بر آن می‌باشد. به‌علت بحران مالی و نگرانی‌های قوانین و مقرراتی کمیته بال در نظارت بانکداری، احتیاجات مقرراتی برای بانک‌ها برای استفاده خبره از مدل‌های ارزیابی اعتباری برای ارتقای کارایی تخصیص سرمایه ایجاد شد. کمیته‌ای متشکل از نماینده‌های بانک مرکزی و صنعت بانکداری از کشورهای مختلف، راهنماها و استانداردهای وسیعی را برای اجرای بانک‌ها ارائه کرده است (خاشمن، ۵۴۷۷:۲۰۱۱).

به‌خاطر تغییرات صنعت بانکداری و روش‌های مدیریت ریسک و روش‌های نظارت بر بازارهای مالی، کمیته بال یک چارچوب مورد تجدید نظر قرار گرفته را به‌عنوان چارچوب کفایت سرمایه جدید که بال ۲ شناخته می‌شود ارائه داد. در آغاز پیش نیازهای بال ۲ عمومیت‌بخشی به وام‌های مصرف‌کننده و رقابت شدید در بازار مالی آگاهی از پدیده‌های قصور و کوتاهی را برای مؤسسات مالی در وام دادن به متقاضیان بالقوه افزایش داده است. بال ۲ چارچوب منطقی‌تری را برای کفایت سرمایه ارائه می‌دهد تا بانک‌ها را به بهبود پیوسته در توانایی‌های ارزیابی ریسک‌شان تشویق کند (همان، ۵۴۷۷). ارزیابی سیستم هشدار درماندگی مالی موضوع مهمی برای نظارت مسئولین و سرمایه‌گذاران می‌باشد و مؤسسات مالی نقش واسطه‌گری مالی مهمی در اقتصاد بازی می‌کنند. توسعه بخش مالی بر روی سطح توسعه اقتصاد اثر می‌گذارد. ریسک اعتباری، درماندگی مالی را به بانک‌ها تحمیل می‌کند و ارزیابی آن نیازمند تکنیک‌های مدل‌سازی پیشرفته می‌باشد. متعاقباً ریسک اعتباری یکی از تهدیدات عمده باقی می‌ماند که مؤسسات مالی با آن مواجه می‌باشند (لین، ۸۸۳۳:۲۰۰۹).

تکنیک‌های اعتبارسنجی شرکت‌ها

روش‌های آماری به‌کار برده شده برای ارزیابی ریسک اعتباری به دو گروه روش‌های آماری سنتی و روش‌های هوش مصنوعی طبقه‌بندی می‌شوند. روش‌های آماری پیشتر و به کرات در ارزیابی ریسک اعتباری استفاده شده‌اند. این روش‌ها شامل رگرسیون خطی، آنالیز افتراقی، رگرسیون لجستیک و غیره می‌باشند. اخیراً روش‌های هوش مصنوعی به‌منظور ارزیابی ریسک اعتباری خیلی بیشتر

پیشنهاد شده‌اند و به تازگی ایده‌ای کشف شده تا روش‌های سنتی را با روش‌های هوش مصنوعی ترکیب کنند که به نام مدل‌های هیبریدی شناخته می‌شوند (لی و همکاران، ۲۰۱۶:۳۴۴).

آنالیز افتراقی اولین بار توسط فیشر (۱۹۳۶:۱۷۹) پیشنهاد شد. مایرز و فورگی (۱۹۶۳:۸۰۳) و اورگلر (۱۹۷۰:۳۱) اولین کسانی بودند که از رگرسیون خطی برای ارزیابی ریسک اعتباری استفاده نمودند. آلتمن (۱۹۶۸:۵۹۰) از مدل رگرسیون افتراقی در مطالعه‌اش استفاده کرد و یکی از معروف‌ترین مدل‌های امتیازدهی اعتباری را به نام Z-Score ارائه نمود. چاترجی و بارکون^۱ (۱۹۷۰:۱۵۱) اولین بار روش نزدیک‌ترین همسایه را در ارزیابی ریسک اعتباری به کار گرفتند. نزدیک‌ترین همسایه، یک روش ناپارامتریک می‌باشد که یک مقیاس روی فضای داده‌های کاربردی انتخاب می‌کند تا اندازه‌گیری کند که چقدر دورتر از کاربدها هستند. مدل رگرسیون لجستیک برای تخمین ریسک اعتباری اولین بار توسط ویگینتون^۲ (۱۹۸۰:۷۵۹) ارائه شد. رگرسیون لجستیک بسیار انعطاف پذیرتر از آنالیز افتراقی یا رگرسیون خطی می‌باشد زیرا رگرسیون لجستیک پیش فرض‌های اولیه مربوط به متغیرهای مستقل نظیر نرمال بودن توزیع متغیرها، ارتباط خطی یا واریانس معادل در هر گروه را ندارد (تاباچینیک و فیدل^۳، ۲۰۰۱:۴۳۹). ماشین بردار پشتیبان^۴ (SVM) اولین بار در تئوری یادگیری به وسیله کورتس و واپنیک^۵ (۱۹۹۵:۲۵۲) ترویج شد. به علت به کارگیری عملکرد طبقه‌بندی و مبانی نظری، خیلی زود برای مسائل امتیازدهی اعتباری معرفی شد (برای مثال بائنس و همکاران، ۲۰۰۳:۱۲۸؛ هانگ و همکاران، ۲۰۰۷:۸۵۵؛ مارتنز و همکاران^۶، ۲۰۰۷:۱۴۷۵؛ هریس^۷، ۲۰۱۵:۷۴۳؛ یائو، کروک و آندریوا^۸، ۲۰۱۵:۵۲۹).

شواهدی از به کارگیری روش‌های آماری سنتی نیز به منظور ارزیابی ریسک اعتباری وجود دارد (بایس و همکاران، ۱۹۸۹:۵؛ استینیکرس و گووئرتس، ۱۹۸۹:۳۱؛ باناسیک و همکاران، ۲۰۰۱:۹۹۸). دوه^۹ و همکاران (۱۹۹۸:۴۱۲) یافتند که مدل‌های شبکه‌ای، عملکرد بهتری در زیرمجموعه آموزش یک مدل نسبت به رگرسیون لجستیک دارند. ولی به عنوان یک روش ناپارامتریک، یک عیب ANN، این است که ساختار پیچیده تری دارد و تفسیر آن به زبان ساده خیلی نسبت به مدل‌هایی که مبتنی بر ضرایب، معناداری و غیره هستند سخت‌تر است. به علاوه قابلیت تعمیم‌پذیری ANN

¹ Chatterjee & Barcun

² Wiginton

³ Tabachnick & Fidell

⁴ Support Vector Machine

⁵ Cortes & Vapnik

⁶ Martens

⁷ Harris

⁸ Yao, Crook & Andreeva

⁹ Duh

محدود است. یعنی عملکرد پیش‌بینی در مجموعه آزمایش^۱ خیلی پائین‌تر از مجموعه آموزش^۲ (دوه و همکاران، ۱۹۹۸:۴۰۷) است.

رگرسیون لجستیک مفروضات کمتر و منعطف‌تری دارد. زیرا در رگرسیون لجستیک نیازی به نرمال بودن متغیرهای مستقل، ارتباط خطی یا واریانس معادل در هرگروه نمی‌باشد (تاباچینک و فیدل، ۲۰۰۱:۴۳۹).

بنابراین رگرسیون لجستیک به‌عنوان یک جزء از مدل هیبریدی پیشنهادی انتخاب می‌شود. استفاده از رگرسیون لجستیک در ارزیابی دارای دو مزیت است. اولاً به‌عنوان یکی از روش‌های آماری سنتی، به‌عنوان یک روش پارامتریک شناخته می‌شود که قابلیت تفسیر بالایی در پارامترها دارد. چون که تکنیک‌های مدل مانند نیکویی برازش، آزمون ضرایب و معناداری متغیرهای ورودی و غیره در مدل‌های رگرسیون لجستیک در دسترس می‌باشند. به‌علاوه در مقایسه با ANN قدرت اعتبارسنجی متقابل^۳ قوی‌تر است. این بدان معنی است که قدرت تعمیم‌پذیری رگرسیون لجستیک بالاتر می‌باشد. به هر حال از معایب روش رگرسیون لجستیک این است که صحت پیش‌بینی آن خیلی بالا نیست (دریسیتل و اوهنو-ماچادو^۴، ۲۰۰۲:۳۵۴).

در مقایسه با سایر فن‌آوری‌های هوش مصنوعی، برای مثال، الگوریتم ژنتیک، با ANN، ریشه‌های مشابه مشترکی در شناسایی الگوهای آماری با رگرسیون لجستیک دارد و به‌عنوان تعمیم‌پذیری در درجه بعدی لحاظ می‌شود (دریسیتل و اوهنو-ماچادو، ۲۰۰۲:۳۵۷). به‌خاطر توانایی یادگیری بالای سیستم هوش مصنوعی، ANN، توانایی پیش‌بینی خوبی دارد.

تعدادی از مطالعات از آنالیز رگرسیون افتراقی جهت امتیازدهی اعتباری استفاده کردند (برای مثال، هند، اولیور و لان^۵، ۱۹۹۸:۶۴۲؛ عبدو و پوینتون، ۲۰۱۱:۶۹؛ محمودی و دامن^۶، ۲۰۱۵:۲۵۱۱). به هر حال پیشنهاد می‌شود که رگرسیون افتراقی با نقاط داده‌های بی‌نهایت یا با فرض کوواریانس یکسان در یک گروه، باعث ارببی می‌شود (مالهوترا و مالهوترا^۸، ۲۰۰۳:۵).

صدیقی^۹ (۲۰۰۵:۶۳) نشان داد که تخمین ریسک اعتباری می‌تواند به‌عنوان یک مسأله طبقه‌بندی باینری (صفر و یک) دیده شود و بدین‌سان، رگرسیون لجستیک برای به‌کار بردن جهت

^۱ Testing set

^۲ Training set

^۳ Cross-Validation

^۴ Dreiseitl & Ohno-Machado

^۵ Hand, Oliver & Lunn

^۶ Abdou & Pointon

^۷ Mahmoudi, N., & Duman

^۸ Malhotra, R., & Malhotra

^۹ Siddiqi

تخمین ریسک اعتباری مناسب می‌باشد. این روش به‌وسیله (عبدو، ای-ماسری و پوینتون^۱، ۲۰۰۷:۷؛ باسنس^۲ و همکاران، ۲۰۰۳:۱۲۹؛ کروک^۳ و همکاران، ۲۰۰۷:۱۴۵۲) به‌کار گرفته شد.

در سال‌های اخیر به‌علت توسعه فناوری‌های اطلاعاتی و محاسباتی، روش‌های هوش مصنوعی به‌عنوان فن‌آوری‌های نوظهور برای ارزیابی ریسک اعتباری به‌کار گرفته شده‌اند. برای مثال، هانگ، چن و وانگ^۴ (۲۰۰۷:۸۴۸) یافتند که تکنیک‌های هوش مصنوعی در امتیازدهی اعتباری بهتر از روش‌های آماری سنتی می‌باشند. الگوریتم ژنتیک، نزدیک‌ترین همسایه، ماشین بردار پشتیبان و شبکه‌های عصبی مصنوعی برای مسائل امتیازدهی اعتباری به‌کار گرفته شدند.

در طی دهه‌های اخیر، الگوریتم ژنتیک به‌وسیله هانگ و همکاران (۲۰۰۷:۸۴۷)، اعتمادی، انواری رستمی و دهکردی^۵ (۲۰۰۹:۳۲۰۴) و کوزنی^۶ (۲۰۱۵:۲۹۹۹) به‌کار گرفته شده‌اند. لین (۲۰۰۹:۸۳۳۳) اولین نفری بود که در زمینه مالی از ترکیب ANN و رگرسیون لجستیک برای پیش‌بینی درماندگی بانک‌ها با استفاده از داده‌های ۱۱ اقتصاد نوظهور استفاده کردند. او صحت مدل هیبریدی ANN و رگرسیون لجستیک را بیش از ۸۰ درصد ارزیابی کرد. درحالی‌که مدل‌های تکی صحتی بین ۷۱٫۲٪ و ۷۵٫۳٪ را نشان دادند.

مطالعات گذشته پیشنهاد می‌دهند که مدل‌های رگرسیون خطی ممکن است به‌وسیله مفروضات یک رابطه خطی بین متغیرهای ورودی و متغیر خروجی محدود شوند (سوسترسیک^۷ و همکاران، ۲۰۰۹:۴۷۳۶). به‌علاوه مدل رگرسیون افتراقی ممکن است به‌خاطر نقاط داده‌های بی‌نهایت دچار اریبی شوند یا فرض کوواریانس معادل هر گروه محقق نشود (مالهوترا و مالهوترا، ۲۰۰۳:۵). در مقابل، رگرسیون لجستیک مفروضات کمتر و منعطف‌تری دارد. زیرا در رگرسیون لجستیک نیازی به نرمال بودن متغیرهای مستقل، ارتباط خطی یا واریانس معادل در هر گروه نمی‌باشد (تاباچینک و فیدل، ۲۰۰۱:۴۳۹).

شبکه‌های عصبی مصنوعی (ANN) یک الگوریتم هوش مصنوعی است که اجازه یادگیری را به‌وسیله تجربه می‌دهد تا رابطه بین ویژگی‌های قرض‌گیرنده و احتمال نکول اعتباری را تشخیص دهد (لی و همکاران، ۲۰۱۶:۳۴۴). بسیاری از مطالعات پیشین پیشنهاد می‌دهند که ANN می‌تواند در ارزیابی ریسک اعتباری به‌طور خیلی مؤثری به‌کار برده شود (دسای و همکاران^۸،

¹ Abdou, El-Masry, & Pointon

² Baesens

³ Crook

⁴ Huang, Chen & Wang

⁵ Etemadi, Rostamy & Dehkordi

⁶ Kozeny

⁷ Šušteršič

⁸ Desai

۱۹۹۶:۳۶؛ پیراموتو^۱، ۱۹۹۹:۳۲۰؛ آنجلینی و همکاران، ۲۰۰۸:۷۵۳؛ سای و وو، ۲۰۰۸:۲۶۴۰؛ خاشمن^۲، ۲۰۱۱:۵۴۸۳؛ سوی دانه و کوکا داگلی^۳، ۲۰۱۵:۳؛ ژائو و همکاران^۴، ۲۰۱۵:۳۵۰۹). به‌تازگی در ادبیات پیشنهاد شده‌است که مدل‌های اعتباری هیبریدی از مدل‌های انفرادی ارائه‌شده در بالا عملکرد بهتری دارد برای مثال چن و لی^۵ (۲۰۱۰:۴۹۰۲) یک مدل SVM را با چندین روش دیگر از قبیل آنالیز رگرسیون افتراقی ترکیب کردند آنها یافتند که مدل‌های آنالیز رگرسیون افتراقی - SVM عملکرد بهتری نسبت به مدل‌های تکی دارند. لیانگ^۶ و همکاران (۲۰۱۵:۲۹۶) یافتند که اگر رگرسیون افتراقی یا الگوریتم ژنتیک با SVM ترکیب شوند عملکرد بهبود می‌یابد. همچنین مطالعات دیگر پیشنهاد می‌دهند که مدل‌های هیبریدی با الگوریتم ژنتیک و ANN عملکرد بهتری دارند (آریفوویچ و گناکای^۷، ۲۰۰۱:۵۹۲؛ بلانکو^۸ و همکاران، ۲۰۰۱:۹۹؛ اورسکی و همکاران، ۲۰۱۲:۱۲۶۰۵؛ همدانی^۹ و همکاران، ۲۰۱۳:۸۶؛ اورسکی و اورسکی^{۱۰}، ۲۰۱۴:۲۰۶۳). پژوهش حاضر براساس پژوهش لی و همکاران (۲۰۱۶) براساس ادبیات مدل هیبریدی به‌وسیله ترکیب ANN با رایج‌ترین روش امتیازدهی اعتباری سنتی، یعنی رگرسیون لجستیک بنا نهاده شده‌است. هدف از پژوهش حاضر تخمین یک مدل هیبریدی است که ANN را با روش آماری سنتی یکپارچه می‌سازد.

مدل هیبریدی ANN/LOGISTIC، ANN را با رگرسیون لجستیک یک‌پارچه می‌سازد. دربرگیری رگرسیون لجستیک، قابلیت تفسیر و اعتبارسنجی متقابل مدل را بهبود می‌بخشد، درحالی‌که استفاده از ANN صحت مدل پیشنهادی را بهبود می‌بخشد. بدین‌سان مدل هیبریدی پیشنهادی ANN/LOGISTIC می‌تواند بر نقائص هر دو مدل فائق آید و مزیت‌های تشریح شده در بالا را توسعه دهد. اما مدل پیشنهادی لی و همکاران (۲۰۱۶:۳۴۷) بدون محدودیت نیست. قابل ذکر است به مانند ANN، مدل هیبریدی معمولاً به دوره یادگیری و آموزش طولانی‌تر با داده‌های کافی به‌منظور دستیابی به بهترین دقت نیاز دارد.

میرغفوری و عاشوری (۱۳۹۴) در پژوهشی به ارزیابی ریسک اعتباری مشتریان بانک‌ها پرداختند. در این تحقیق از یک روش پارامتریک (رگرسیون لجستیک) و یک روش ناپارامتریک

¹ Piramuthu

² Khashman

³ Soydaner & Kocadağlı

⁴ Zhao

⁵ Chen & Li

⁶ Liang

⁷ Arifovic, J., & Gencay

⁸ Blanco

⁹ Hamadani

¹⁰ Oreski & Oreski

(درخت تقسیم و رگرسیون) برای ایجاد مدل امتیازدهی اعتباری استفاده شده است. نتایج آنها نشان داد که روش‌های ناپارامتریک دارای دقت قابل رقابتی با روش‌های پارامتریک می‌باشند.

صداقت‌پرست و همکاران (۱۳۹۴) در پژوهشی به ارزیابی ریسک مشتریان حقوقی با استفاده از شاخص‌های عملکردی در بانک ملت استان آذربایجان شرقی پرداختند. آنها یافتند که کارایی شرکت بیشترین قدرت پیش‌بینی کنندگی احتمال عدم نکول تسهیلات را داراست. در مقابل، در بین شاخص‌های مالی، تنها اندازه شرکت (فروش) معنی‌دار بود.

جعفری اسکندری و روحی (۱۳۹۶) در پژوهشی تحت عنوان "مدیریت ریسک اعتباری مشتریان بانکی با استفاده از روش ماشین بردار تصمیم بهبودیافته با الگوریتم ژنتیک با رویکرد داده کاوی" به ارائه الگویی با استفاده از روش‌های داده کاوی برای پیش‌بینی شاخص نرخ وصول مشتریان پرداختند. نتایج آنها دقت بیشتری را برای هدف پیش‌بینی درصد وصول مطالبات قراردادهای با احتمال ریسک مطالباتی بالا قبل از اعطای تسهیلات نشان داد.

ناجی اصفهانی و رستگار (۱۳۹۷) در پژوهشی با عنوان "برآورد ریسک اعتباری مشتریان با استفاده از تحلیل چند بعدی ترجیحات (مطالعه موردی یک بانک تجاری در ایران)" به ارزیابی و پیش‌بینی شرکت‌های متقاضی تسهیلات از یک بانک تجاری در ایران پرداختند. نتایج حاکی از کارایی روش تحلیل چند بعدی ترجیحات جهت پیش‌بینی رفتار اعتباری مشتریان بانک می‌باشد.

محمدی و جوهری (۱۳۹۷) پژوهشی را با عنوان "ارزیابی مدل‌های ریسک اعتباری بانک‌ها با رویکرد ویژگی‌های اخلاقی مشتریان" به انجام رساندند. در این پژوهش آنها با ارائه تکنیک مدل‌های چندسطحی، به بررسی و شرح این روش برای طراحی مدل ریسک اعتباری مشتریان بانک‌ها و لحاظ نمودن ویژگی‌های اخلاقی مشتریان به عنوان متغیر توضیحی در مدل پرداختند. نتایج آنها نشان داد که در یک مدل رگرسیون لجستیک و با رویکرد چندسطحی، لحاظ ویژگی‌های اخلاقی مشتریان به عنوان یک متغیر توضیحی در کنار سایر متغیرهای توضیحی (نظیر سابقه همکاری با بانک، درآمد، نسبت های مالی مشتریان حقوقی و ...)، نقش مهمی را می‌تواند در بیان رفتار ریسک اعتباری ایفا نماید.

جدول ۱ کلیه مدل‌های آماری به کار گرفته شده برای ارزیابی اعتباری شرکت‌ها را با مزایا و معایب آنها نشان می‌دهد. با نگاهی به مزایا و معایب مدل‌های مختلف، علت استفاده این پژوهش از مدل هیبریدی ANN/LOGISTIC مشخص می‌گردد. استفاده از رگرسیون لجستیک قابلیت تعمیم‌پذیری مدل را افزایش می‌دهد. درحالی‌که استفاده از ANN صحت مدل پیشنهادی را بهبود می‌بخشد.

جدول ۱. انواع روش‌های ارزیابی اعتباری شرکت‌ها و بیان مزایا و معایب روش‌ها

روش‌های آماری سنتی		
معایب	مزایا	نوع روش
محدودیت مفروضات یک رابطه خطی		رگرسیون خطی
فرض کوواریانس یکسان در یک گروه در رگرسیون افتراقی باعث ایجاد اریبی می‌شود.		رگرسیون افتراقی
از معایب روش رگرسیون لجستیک این است که صحت پیش‌بینی آن خیلی بالا نیست (دریسیتل و اوهنو-ماچادو، ۲۰۰۲:۳۵۴).	۱- بسیار انعطاف‌پذیرتر از آنالیز افتراقی یا رگرسیون خطی می‌باشد. زیرا رگرسیون لجستیک پیش فرض‌های اولیه مربوط به متغیرهای مستقل نظیر نرمال بودن توزیع متغیرها، ارتباط خطی یا واریانس معادل در هر گروه را ندارد (تاباچینیک و فیدل، ۲۰۰۱:۴۳۹). ۲- رگرسیون لجستیک در ارزیابی دارای دو مزیت است. اولاً به‌عنوان یکی از روش‌های آماری سنتی، به‌عنوان یک روش پارامتریک شناخته می‌شود که قابلیت تفسیر بالایی در پارامترها دارد. چون تکنیک‌های مدل مانند نیکویی برازش، آزمون ضرایب و معناداری متغیرهای ورودی و غیره در مدل‌های رگرسیون لجستیک در دسترس می‌باشند. به‌علاوه در مقایسه با ANN قدرت اعتبارسنجی متقابلش قوی‌تر است. این بدان معنی است که قدرت تعمیم‌پذیری رگرسیون لجستیک بالاتر می‌باشد. ۳- صدیقی (۲۰۰۵:۶۳) نشان داد که تخمین ریسک اعتباری می‌تواند به‌عنوان یک مسأله طبقه‌بندی باینری (صفر و یک) دیده شود و بدین‌سان، رگرسیون لجستیک برای به‌کار بردن جهت تخمین ریسک اعتباری مناسب می‌باشد.	رگرسیون لجستیک

روش‌های هوش مصنوعی		
معایب	مزایا	نوع روش
	عملکرد طبقه‌بندی و مبانی نظری خیلی خوب	ماشین بردار پشتیبان SVM
۱- یک ساختار پیچیده‌تری دارد و تفسیر آن به زبان ساده خیلی نسبت به مدل‌هایی که مبتنی بر ضرایب، معناداری و غیره هستند سخت‌تر است. به‌علاوه قابلیت تعمیم‌پذیری ANN محدود است. یعنی عملکرد پیش‌بینی در مجموعه آزمایش خیلی پائین‌تر از مجموعه آموزش (دوه و همکاران، ۱۹۹۸:۴۰۷) است. ۲- لی و همکاران (۲۰۱۶:۳۴۵) پیشنهاد دادند که شبکه عصبی ممکن نیست به ثبات تکنیک‌های آماری استاندارد باشد.	به‌خاطر توانایی یادگیری بالای سیستم هوش مصنوعی، ANN، توانایی پیش‌بینی خوبی دارد.	ANN
	به‌عنوان درجه بعدی در تعمیم‌پذیری بعد از رگرسیون لجستیک قرار دارد (دریستل و اوونو-ماچادو، ۲۰۰۲:۳۵۷).	الگوریتم ژنتیک
به مانند ANN، مدل هیبریدی معمولاً به دوره یادگیری و آموزش طولانی‌تر با داده‌های کافی به‌منظور دستیابی به بهترین دقت نیاز دارد.	۱- لین (۲۰۰۹:۸۳۳۳) صحت مدل هیبریدی ANN و رگرسیون لجستیک را بیش از ۸۰ درصد ارزیابی کرد. درحالی‌که مدل‌های تکی صحتی بین ۷۱,۲٪ و ۷۵,۳٪ را نشان دادند. ۲- دربرگیری رگرسیون لجستیک، قابلیت تفسیر و اعتبارسنجی متقابل مدل را بهبود می‌بخشد، درحالی‌که استفاده از ANN صحت مدل پیشنهادی را بهبود می‌بخشد.	مدل هیبریدی ANN/LOGISTIC
	چن و لی (۲۰۱۰:۴۹۰۲) یک مدل SVM را با چندین روش دیگر از قبیل آنالیز رگرسیون افتراقی ترکیب کردند آنها یافتند که مدل‌های آنالیز رگرسیون افتراقی - SVM عملکرد بهتری نسبت به مدل‌های تکی دارند. لیانگ و همکاران (۲۰۱۵:۲۹۶) یافتند که اگر رگرسیون افتراقی یا الگوریتم ژنتیک با SVM ترکیب شوند عملکرد بهبود می‌یابد.	مدل هیبریدی رگرسیون افتراقی - SVM

مدل هیبریدی رگرسیون افتراقی - SVM	چن و لی (۲۰۱۰:۴۹۰۲) یک مدل SVM را با چندین روش دیگر از قبیل آنالیز رگرسیون افتراقی ترکیب کردند آنها یافتند که مدل‌های آنالیز رگرسیون افتراقی - SVM عملکرد بهتری نسبت به مدل‌های تکی دارند. لیانگ و همکاران (۲۰۱۵:۲۹۶) یافتند که اگر رگرسیون افتراقی یا الگوریتم ژنتیک با SVM ترکیب شوند عملکرد بهبود می‌یابد.
--------------------------------------	---

۲. روش‌شناسی پژوهش

۲-۱. اصول یک شبکه عصبی پیش‌خور^۱ (BP)

یک شبکه عصبی BP نوعی از الگوریتم هوش مصنوعی در ANN می‌باشد. در این مطالعه یک شبکه عصبی پیش‌خور برای ساخت مدل انتخاب می‌شود. شبکه عصبی BP یک شبکه عصبی پیش‌خور دو مرحله‌ای یا چند لایه می‌باشد که تابع انتقال نورون هایش، تابع سیگموئید می‌باشد (آنجلینی و همکاران، ۲۰۰۸:۳۱۲۰۳). خروجی شبکه بین حجم ۰ و ۱ پیوسته می‌باشد. این شبکه عصبی پیش‌خور می‌تواند نقشه برداری از ورودی تا خروجی هر تابع غیرخطی را محقق سازد. یک شبکه عصبی پیش‌خور معمولی، یک لایه ورودی، یک لایه پنهان و شبکه سلسله‌مراتبی سه لایه‌ای پیش‌خور لایه خروجی می‌باشد (لی و همکاران، ۲۰۱۶:۳۴۵؛ میرکین، ۱۹۹۶:۷۴). ساختار شبکه در شکل ۱ به تصویر کشیده شده است. فرض کنید:

$$A^K = (a_1^k, a_2^k, a_3^k, \dots, a_n^k) \quad \text{بردار الگوی ورودی}$$

$$Y^k = (y_1^k, y_2^k, \dots, y_n^k) \quad \text{و بردار خروجی مطلوب است.}$$

$$B^k = (b_1^k, b_2^k, \dots, b_n^k) \quad \text{خروجی واحد لایه میانی می‌باشد.}$$

$$C^k = (c_1^k, c_2^k, \dots, c_n^k) \quad k = 1, 2, \dots, m \quad \text{خروجی واحد لایه خروجی است.}$$

وزن‌های اتصال لایه میانی به لایه ورودی $[w_{ij}]$, $i=1,2,\dots,n$; $j=1,2,\dots,p$ می‌باشد.

وزن‌های اتصال لایه میانی به لایه خروجی $[v_{jt}]$, $j=1,2,\dots,p$; $t=1,2,\dots,q$ می‌باشد.

آستانه خروجی ارزش هر واحد لایه میانی $\{\theta_j\}$, $j=1,2,\dots,p$

¹ Back Propagation

آستانه خروجی ارزش هرواحد لایه خروجی برابر است $[\gamma_t]$, $t=1,2,\dots,q$ با

براساس فرضیات بالا، مراحل یادگیری ویژه یک شبکه عصبی پس انتشار می تواند به صورت زیر بیان شود (شکل ۲):

(a). تنظیم همه پارامترهای قابل تعدیل. برای مثال وزن های اتصال لایه میانی به لایه ورودی $[w_{ij}]$ ، اتصال لایه میانی به لایه خروجی $[v_{jt}]$ آستانه خروجی ارزش هر واحد لایه میانی $\{\theta_j\}$ ، و آستانه بازده مقدار لایه میانی هر واحد از آستانه بازده مقدار لایه بازده هر واحد $\{\gamma_t\}$ عدد تصادفی بین $(-1+)$ می باشد (لین، ۲۰۰۹:۸۳۳۴؛ لی و همکاران، ۲۰۱۶:۴۳۵).

(b). محاسبه نمونه های ورودی برای به دست آوردن ارزش خروجی هر لایه. فرمول به شرح ذیل می باشد.

$$b_j^k = f[\sum w_{ij}a_j^k - \theta_j], j = 1, 2, \dots, p \quad (1)$$

$$c_t^k = f[\sum v_{jt}b_j^k - \gamma_t], t = 1, 2, \dots, p \quad (2)$$

(c). محاسبه خطا و گرادیان موضعی لایه خروجی.

(d). تعدیل وزن های لایه خروجی.

$$v_{jt}(N+1) = v_{jt}(N) + \alpha d_t^k b_j^k, 0 < \alpha \quad (3)$$

که در معادله بالا، α ضریب یادگیری می باشد.


(e). تعدیل وزن های لایه پنهان

$$w_{ij}(N+1) = w_{ij}(N) + \beta e_j^k a_i^k, \beta < 1 \quad (4)$$

که در معادله بالا، β ضریب یادگیری می باشد.


(f). شبکه به یادگیری ادامه می دهد تا زمانی که به صحت و دقت مورد نظر برسد.

$$E(t) = \frac{1}{2} \sum_{k=1}^m \sum_{i=1}^q (y_i - c_i)^2 \quad (5)$$



شکل ۱. ساختار یک شبکه عصبی پیش‌خور

منبع: لی و همکاران (۲۰۱۶:۳۴۶)



شکل ۲. مراحل یادگیری ویژه یک الگوریتم پس انتشار برای شبکه عصبی پیش خور

منبع: لی و همکاران (۲۰۱۶:۳۴۶)

بعد از فرآیند بالا، فرآیند یادگیری BP کامل می‌شود. الگوریتم BP که در اصل روش تندترین کاهش گرادیان^۱ می‌باشد. وزن‌ها را در جهت تندترین کاهش تنظیم می‌کند (گرادیان منفی). با این وجود، می‌توان متوجه شد اگر چه گرادیان منفی خیلی سریع کاهش می‌یابد و همگرایی خیلی سریع تولید نمی‌شود (ژانگ^۲ و همکاران، ۱۹۹۸:۴۸).

۲-۲. اصول رگرسیون لجستیک

رگرسیون لجستیک از روش حداکثر درست‌نمایی استفاده می‌کند تا مدل را تخمین بزند. مدل رگرسیون لجستیک به شرح زیر خواهد بود (لی و همکاران، ۲۰۱۶:۳۴۷؛ لین، ۲۰۰۹:۸۳۳۴).

$$\begin{aligned} p_i &= p(y_i = 1 | x_{1i}, x_{2i}, \dots, x_{ki}) \\ &= \frac{\exp(\alpha + \beta_1 x_1 + \dots + \beta_k x_k)}{1 + \exp(\alpha + \beta_1 x_1 + \dots + \beta_k x_k)} \\ &= \frac{e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}}}{1 + e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}}} \end{aligned} \quad (۶)$$

تصور کنید شرکت بدون ریسک اعتبار مالی برابر ۰ است پس احتمال شرطی شرکت بدون ریسک اعتبار مالی ($y_i = 0$) برابر است با: $p(y_i = 0 | x_{1i}, x_{2i}, \dots, x_{ki}) = 1 - p_i$ بنابراین می‌توان شاهد احتمال زیر بود:

$$p_{(y_i)} = p_i^{y_i} (1 - p_i)^{1-y_i} \quad (۷)$$

که $y_i = 0$ یا $y_i = 1$ می‌باشد. به‌خاطر اینکه همه مشاهدات مستقل می‌باشند بنابراین احتمال توأم آنها برابر می‌باشد با:

$$L(\theta) = \prod_{i=1}^n p_i^{y_i} (1 - p_i)^{1-y_i} \quad (۸)$$

برای ساده کردن محاسبه، تابع درست‌نمایی لگاریتمی به صورت زیر است (لی و همکاران، ۲۰۱۶:۳۴۷):

^۱ Gradient Steepest Descent

^۲ Zhang

$$\begin{aligned}
\ln[L(\theta)] &= \ln \left[\prod_{i=1}^n p_i^{y_i} (1 - p_i)^{1-y_i} \right] \\
&= \sum_{i=1}^n [y_i \ln(p_i) + (1 - y_i) \ln(1 - p_i)] \\
&= \left[y_i \ln \left(\frac{p_i}{1 - p_i} \right) + \ln(1 - p_i) \right] \\
&= \sum_{i=1}^n y_i (\alpha + \beta x_i) + \ln \left(1 - \frac{e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}}}{1 + e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}}} \right) \\
&= \sum_{i=1}^n [y_i (\alpha + \beta x_i) + \ln(1 + e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}})] y
\end{aligned} \tag{۹}$$

اینها توابع درست‌نمایی لگاریتمی می‌باشند و تخمین حداکثر درست‌نمایی از پارامترهای α و $\beta_j (j = 1 \dots k)$ به دست می‌آیند. در نتیجه ما می‌توانیم به تابع احتمال زیر برسیم (همان، ۳۴۷):

$$\frac{\partial \ln[L(\theta)]}{\partial \alpha} = \sum_{i=1}^n \left[y_i - \frac{e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}}}{1 + e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}}} \right] \tag{۱۰}$$

$$\frac{\partial \ln[L(\theta)]}{\partial \alpha} = \sum_{i=1}^n \left[y_i - \frac{e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}}}{1 + e^{\alpha + \sum_{j=1}^k \beta_j x_{ji}}} \right] x_i \tag{۱۱}$$

K+1 معادله برای تخمین α و $\beta_j (j = 1 \dots k)$ مورد محاسبه قرار می‌گیرد. این فرایند تخمین حداکثر درست‌نمایی است.

۳-۲. مدل هیبریدی ANN/LOGISTIC

آموزش مدل هیبریدی ANN/LOGISTIC در این پژوهش به شرح ذیل می‌باشد (لی و همکاران، ۲۰۱۶:۳۴۷؛ قاسمی و دنیایی هریس، ۱۳۹۵:۱۶۴):

مرحله اول: تجزیه و تحلیل اجزای اصلی با متغیرهای مستقل به‌منظور حذف مشکلات هم خطی سپس رگرسیون لجستیک با اجزای اصلی و متغیر وابسته اجرا می‌شود. مدل رگرسیون لجستیک احتمال پیش‌بینی رگرسیون لجستیک را فراهم می‌کند. مقادیر احتمال پیش‌بینی به‌عنوان یک متغیر جدید تحت عنوان نتایج رگرسیون لجستیک تعریف می‌شود.

مرحله دوم: آموزش شبکه عصبی پایه با متغیرهای مستقل به‌عنوان ورودی و متغیر وابسته به‌عنوان خروجی. احتمال پیش‌بینی فراهم شده به‌وسیله شبکه عصبی، نتایج شبکه عصبی مصنوعی نامگذاری می‌شود.

مرحله سوم: آموزش شبکه عصبی نهایی با اجزای اصلی، نتایج رگرسیون لجستیک و نتایج شبکه عصبی مصنوعی به‌عنوان ورودی‌ها و متغیر وابسته (متغیر ریسک اعتباری) به‌عنوان خروجی. فرایند مدل هیبریدی ریسک اعتباری ANN/LOGISTIC در شکل ۳ به تصویر کشیده شده است. لایه اول لایه ورودی است. لایه دوم لایه پنهان و آخرین لایه، لایه خروجی است.

۴-۲. شاخص‌های اعتبار

به‌منظور مقایسه عملکرد مدل‌های مختلف، چندین شاخص اعتبار بخشی توسط (لی و همکاران، ۲۰۱۶:۳۴۷؛ خاشمن، ۲۰۱۱:۵۴۷۸) تعریف شده است.


۴-۲-۱. خطای مجذور میانگین^۱ (MSE)

MSE یکی از نشانگرهاست که می‌تواند عملکرد مدل را توضیح دهد که به‌وسیله معادله ذیل محاسبه می‌شود.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (۱۲)$$

n تعداد مجموعه داده‌هاست، $\hat{Y}_i$ ارزش پیش‌بینی مدل است. Y_i ارزش مشاهده شده است که هرچه مقدار MSE کمتر باشد، عملکرد مدل، بهتر است.

^۱ Mean Squared Error



شکل ۳. فرایند مدل هیبریدی ریسک اعتباری ANN/LOGISTIC

منبع: لی و همکاران (۲۰۱۶:۳۴۷)

۲-۴-۲. ضریب R

ضریب R شاخص دیگری برای تشریح رابطه بین خروجی‌ها و اهداف است. R به عنوان ریشه تفاوت بین یک و خطای میانگین مجذور نرمال شده است که به صورت زیر بیان می‌شود.

$$R = \sqrt{1 - NMSE^1} \quad (۱۳)$$

NMSE در واقع MSE نرمال شده است. هرچه مقدار R بالاتر باشد نشان‌دهنده این است که مدل ما بهتر است.

¹ Normalized Mean Squared Error

۲-۴-۳. میزان صحت (Accuracy Rate)

میزان صحت، نشانگری است که توانایی پیش‌بینی مدل را بیان می‌کند. میزان دقت به‌عنوان تعداد کل پیش‌بینی‌های صحیح در دو گروه مختلف تقسیم بر تعداد کل نمونه‌هاست که مطابق معادله ذیل به‌دست می‌آید.

$$Accuracy = \frac{p_1 + p_2}{Z_1 + Z_2} \times \%100 \quad (14)$$

p_1 تعداد پیش‌بینی صحیح در گروه‌های فاقد اعتبار و p_2 تعداد پیش‌بینی‌های صحیح در گروه‌های دارای اعتبار، Z_1 تعداد گروه‌های فاقد اعتبار و Z_2 تعداد گروه‌های دارای اعتبار هستند.

۲-۵. فرضیه‌های پژوهش

- ۱- بین اعتبار مدل رگرسیون لجستیک و مدل شبکه‌های عصبی مصنوعی در ارزیابی ریسک اعتباری شرکت‌های تولیدی پذیرفته شده در بورس اوراق بهادار تهران تفاوت وجود دارد.
- ۲- بین اعتبار مدل رگرسیون لجستیک و مدل هیبریدی در ارزیابی ریسک اعتباری شرکت‌های تولیدی پذیرفته شده در بورس اوراق بهادار تهران تفاوت وجود دارد.
- ۳- بین اعتبار مدل شبکه‌های عصبی مصنوعی و مدل هیبریدی در ارزیابی ریسک اعتباری شرکت‌های تولیدی پذیرفته شده در بورس اوراق بهادار تهران تفاوت وجود دارد.

۲-۶. جامعه آماری پژوهش

جامعه آماری پژوهش شامل کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران که قبل از سال ۱۳۸۹ در بورس پذیرفته شده و تا پایان سال ۱۳۹۵ جزء شرکت‌های بورسی باقی مانده باشند بعد از اعمال شرایط زیر می‌باشند.

جدول ۲. فرآیند غربالگری جامعه آماری پژوهش

فرآیند گردآوری داده‌ها	تعداد شرکت‌ها
کلیه شرکت‌های پذیرفته شده در بورس که قبل از سال ۸۹ در بورس پذیرفته شده و تا پایان سال ۹۵ در بورس تداوم فعالیت داشته باشند.	۳۳۵
کسر می‌شود: بانک‌ها و مؤسسات مالی، شرکت‌های سرمایه‌گذاری، هلدینگ‌ها و سایر واسطه‌های مالی	(۶۵)
کسر می‌شود: شرکت‌ها با پایان سال مالی به غیر از ۲۹ اسفند	(۱۴۳)
کسر می‌شود: شرکت‌هایی که در طول دوره تحقیق تغییر سال مالی یا تغییر فعالیت داشته باشند	(۵)
کسر می‌شود: شرکت‌هایی که نماد آنها بیش از ۳ ماه در بورس متوقف شده باشد.	(۱۷)
کسر می‌شود: شرکت‌ها با داده‌های مالی ناقص در مورد متغیرهای پژوهش	(۱۵)
تعداد شرکت‌ها در تجزیه و تحلیل نهایی	۹۰

در نهایت پس از اعمال شرایط فوق، تعداد ۹۰ شرکت برای انجام آزمون فرضیه‌های تحقیق انتخاب شدند.

۷-۲. متغیرهای پژوهش

۷-۲-۱. متغیر وابسته

متغیر وابسته این تحقیق ریسک اعتباری می‌باشد. لی و همکاران (۲۰۱۶) این متغیر را یک متغیر موهومی در نظر گرفتند به طوری که اگر شرکت دارای ریسک اعتباری باشد، آن متغیر عدد صفر و در غیر این صورت عدد یک به آن متغیر تعلق می‌گیرد. آنها شرکت‌هایی را که در پرداخت‌هایشان نکول داشتند، قادر به پرداخت بدهی‌هایشان نباشند، ورشکسته باشند و یا به‌خاطر ورشکستگی در مراحل آخر تصفیه باشند را شرکت‌های دارای ریسک اعتباری در نظر گرفتند. به‌علت مشکلات افشای چنین اطلاعاتی، در این پژوهش با بهره‌گیری از نظر خبرگان، شرکت‌هایی دارای ریسک اعتباری در نظر گرفته شده‌اند که بدهی‌های جاری به فروش آنها بیش از ۶۰ درصد باشد. اگر

شرکت دارای ریسک اعتباری باشد عدد ۱ و در غیر اینصورت یعنی اگر بدهی‌های جاری به فروش شرکت کمتر از ۶۰ درصد باشد عدد صفر در نظر گرفته می‌شود.

۲-۷-۲. متغیرهای مستقل

متغیرهای مستقل براساس مطالعات پیشین انتخاب شده‌اند. عبدو و پوینتون (۲۰۱۱) در مقاله خود در مورد ریسک اعتباری به این نکته اشاره نمودند که سودآوری شرکت و ساختار سرمایه به کرات برای پیش‌بینی ریسک اعتباری مورد استفاده قرار گرفتند. بلواری و همکاران (۲۰۰۷) شواهدی را گزارش کردند که نسبت‌های نقدینگی شرکت از جمله نسبت جاری بیشترین مورد استفاده را به‌عنوان یک فاکتور ریسک اعتباری در مطالعات پیشین داشته‌اند. کوله (۱۹۹۸) یافت که ویژگی‌های شرکت از قبیل سایز، می‌توانند برای سنجش اعتباری شرکت مؤثر باشند. در این پژوهش براساس پژوهش لی و همکاران (۲۰۱۶) متغیرهای مستقل از ۵ جنبه انتخاب می‌شوند: نسبت‌های سودآوری شرکت، ساختار سرمایه شرکت، نسبت‌های نقدینگی شرکت، نسبت‌های فعالیت شرکت و ویژگی‌های شرکت. شرح کامل متغیرهای پژوهش در جدول ۱ آمده‌است.

جدول ۳. شرح متغیرهای پژوهش

متغیرهای تحقیق	تعریف متغیرها
ریسک اعتباری	شرکت‌هایی دارای ریسک اعتباری در نظر گرفته شده‌اند که بدهی‌های جاری به فروش آنها بیش از ۶۰ درصد باشد. اگر شرکت دارای ریسک اعتباری باشد عدد ۱ و در غیر اینصورت یعنی اگر بدهی‌های جاری به فروش شرکت کمتر از ۶۰ درصد باشد عدد صفر در نظر گرفته می‌شود.
نسبت‌های سودآوری	
ROA ^۱	نسبت سود خالص به دارایی‌های کل شرکت
ROCE ^۲	نسبت سود قبل از بهره و مالیات به سرمایه به خدمت درآمده (دارایی کل - بدهی جاری)
ROE ^۳	نسبت سود خالص به حقوق صاحبان سهام
EBIT_ASST ^۴	نسبت سود قبل از بهره و مالیات به دارایی کل

^۱ Return on Assets

^۲ Return on Capital Employed

^۳ Return on Equity

^۴ Earnings Before Interest and Taxation to Total Assets.

نسبت‌های فعالیت	
A_TURN ^۱	نسبت فروش (درآمد عملیاتی) به خالص دارایی‌ها
SALE_A ^۲	نسبت فروش (درآمد عملیاتی) به دارایی کل
نسبت نقدینگی	
CURRENT ^۳	نسبت دارایی جاری به بدهی جاری
ساختار سرمایه	
LEVERAGE_A ^۴	نسبت بدهی کل به دارایی کل
LEVERAGE_E ^۵	نسبت بدهی کل به حقوق صاحبان سهام
LTTA ^۶	نسبت بدهی بلند مدت به دارایی کل
STTA ^۷	نسبت بدهی جاری به دارایی کل
APR ^۸	نسبت حساب‌های پرداختی به دارایی کل
ARR ^۹	نسبت حساب‌های دریافتی به دارایی کل
TANGIBLE ^{۱۰}	نسبت دارایی‌های مشهود به دارایی کل
WORKING_TASST ^{۱۱}	نسبت سرمایه در گردش به دارایی کل
ویژگی‌های شرکت	
SIZE_A ^{۱۲}	لگاریتم طبیعی دارایی‌های کل شرکت
ANN_RESULT ^{۱۳}	احتمالی پیش‌بینی شبکه عصبی مصنوعی با متغیرهای اصلی به‌عنوان ورودی
LOGISTIC_RESULT ^{۱۴}	احتمال پیش‌بینی مدل رگرسیون لجستیک با متغیرهای آنالیز اجزای اصلی به‌عنوان ورودی

¹ Asset Turnover Ratio

² Sales to Total Assets

³ Current Ratio

⁴ Leverage based on Total Assets

⁵ Leverage based on Equity

⁶ Long Term Debt to Total Assets

⁷ Short Term Debt to Total Assets

⁸ Accounts Payable Ratio

⁹ Accounts Receivable Ratio

¹⁰ Tangible Assets to Total Assets

¹¹ Working Capital to Total Assets

¹² Size based on Total Assets

¹³ Artificial Neural Network Result

¹⁴ Logistic Regression Result

متغیرهای پژوهش با استفاده از نرم افزار ره آورد نوین و مراجعه به سایت Codal.ir و مطالعه گزارش حسابرس مستقل و بازرس قانونی هر شرکت برای پایان هر سال مالی استخراج شده و تجزیه و تحلیل داده‌ها با استفاده از نرم‌افزار متلب صورت گرفته است.

۳. یافته‌های پژوهش

جدول ۴. مقایسه نتایج مدل‌های رگرسیون و شبکه‌های عصبی مصنوعی

نتایج حاصل از مدل شبکه‌های عصبی مصنوعی		نتایج حاصل از مدل رگرسیون لجستیک	
R	۰/۴۷۶۲۸	R	۰/۴۲۹۷۱
MSE	۰/۲۸۶۹۴	MSE	۰/۲۶۶۴۱
Accuracy	۷۵/۱۹۳۵	Accuracy	۷۳/۳۵۸۹

همان‌طور که در جدول ۴ ملاحظه می‌فرمایید ضریب R که نشان‌دهنده قدرت پیش‌بینی می‌باشد در مدل شبکه‌های عصبی مصنوعی نسبت به مدل رگرسیون لجستیک بالاتر است ولی MSE هر چه پایین‌تر باشد بهتر است در اینجا ملاحظه می‌فرمایید که MSE مدل شبکه‌های عصبی مصنوعی بالاتر از مدل رگرسیون لجستیک می‌باشد و این یک نکته منفی برای مدل شبکه‌های عصبی مصنوعی نسبت به مدل رگرسیون لجستیک می‌باشد و ضریب Accuracy مدل رگرسیون لجستیک پایین‌تر از مدل شبکه‌های عصبی مصنوعی می‌باشد که نشانگر دقت بیشتر مدل شبکه عصبی مصنوعی از مدل رگرسیون لجستیک می‌باشد.

جدول ۵. مقایسه نتایج مدل‌های رگرسیون و هیبریدی

نتایج حاصل از مدل هیبریدی		نتایج حاصل از مدل رگرسیون لجستیک	
R	۰/۵۱۶۹۵	R	۰/۴۲۹۷۱
MSE	۰/۲۲۷۲۲	MSE	۰/۲۶۶۴۱
Accuracy	۷۷/۲۷۸۲	Accuracy	۷۳/۳۵۸۹

همان‌طور که در جدول ۵ ملاحظه می‌فرمایید ضریب R که نشان‌دهنده قدرت پیش‌بینی می‌باشد در مدل رگرسیون لجستیک نسبت به مدل هیبریدی کمتر است ولی MSE هر چه

پایین تر باشد بهتر است در اینجا ملاحظه می‌فرمایید که MSE مدل رگرسیون لجستیک بالاتر از مدل هیبریدی می‌باشد و این یک نکته منفی برای مدل رگرسیون لجستیک نسبت به مدل هیبریدی می‌باشد و ضریب Accuracy مدل رگرسیون لجستیک نسبت به مدل هیبریدی پایین تر می‌باشد که نشانگر دقت بیشتر مدل هیبریدی از مدل رگرسیون لجستیک می‌باشد.

جدول ۶. مقایسه نتایج مدل‌های شبکه‌های عصبی مصنوعی و هیبریدی

نتایج حاصل از مدل هیبریدی		نتایج حاصل از مدل شبکه‌های عصبی مصنوعی	
R	۰/۵۱۶۹۵	R	۰/۴۷۶۲۸
MSE	۰/۲۲۷۲۲	MSE	۰/۲۸۶۹۴
Accuracy	۷۷/۲۷۸۲	Accuracy	۷۵/۱۹۳۵

همان‌طور که در جدول ۴ ملاحظه می‌فرمایید ضریب R که نشان‌دهنده قدرت پیش‌بینی می‌باشد در مدل شبکه‌های عصبی مصنوعی نسبت به مدل هیبریدی پایین تر است ولی MSE هر چه پایین تر باشد بهتر است در اینجا ملاحظه می‌فرمایید که MSE مدل شبکه‌های عصبی مصنوعی بالاتر از مدل هیبریدی می‌باشد و این یک نکته منفی برای مدل شبکه‌های عصبی مصنوعی نسبت به مدل هیبریدی می‌باشد و ضریب Accuracy مدل شبکه‌های عصبی مصنوعی نسبت به مدل هیبریدی پایین تر می‌باشد که نشانگر دقت بیشتر مدل هیبریدی از مدل شبکه‌های عصبی مصنوعی می‌باشد.

جدول ۷. ارزیابی نشانگرها

نشانگرها	مدل هیبریدی	مدل رگرسیون لجستیک	مدل شبکه‌های عصبی مصنوعی
MSE	۰/۲۲۷۲۲	۰/۲۶۶۴۱	۰/۲۸۶۹۴
ضریب R	۰/۵۱۶۹۵	۰/۴۲۹۷۱	۰/۴۷۶۲۸
Accuracy	۷۷/۲۷۸۲	۷۳/۳۵۸۹	۷۵/۱۹۳۵

در ارزیابی سه نشانگر بالا متوجه شده‌ایم، مدل هیبریدی در مقایسه با مدل‌های شبکه‌های عصبی مصنوعی و مدل رگرسیون لجستیک در سنجش ریسک اعتباری دقیق‌تر و درست عمل می‌کند.

۴. نتیجه‌گیری

باتوجه به هدف این تحقیق که بررسی دقت مدل هیبریدی ریسک اعتباری، در اعطای وام برای شرکت‌های تولیدی پذیرفته شده در بورس اوراق بهادار است با استفاده از اطلاعات شرکت‌های تولیدی در بورس اوراق بهادار تهران طی سال‌های (۱۳۸۹-۱۳۹۵) است. در فرضیه اول پژوهش مدل‌های رگرسیون لجستیک و شبکه عصبی مصنوعی را مورد آزمون قرار دادیم و نتیجه گرفتیم قدرت پیش‌بینی‌کنندگی و صحت شبکه عصبی مصنوعی بالاتر از رگرسیون لجستیک می‌باشد ولی خطای مجذور میانگین در رگرسیون لجستیک کمتر می‌باشد که این امر تنها نقطه مثبت در رگرسیون لجستیک در مقایسه با شبکه عصبی مصنوعی بود. در فرضیه دوم مدل رگرسیون لجستیک و مدل هیبریدی را مورد ارزیابی قرار دادیم و نتیجه گرفتیم مدل هیبریدی در همه آیت‌ها از مدل رگرسیون لجستیک برتری داشت. نتایج حاصل از فرضیه دوم با یافته‌های شافر (۲۰۰۸:۱۰۳) مطابقت دارد. و در نهایت در فرضیه سوم مدل شبکه عصبی مصنوعی و مدل هیبریدی را مورد مقایسه قرار دادیم و نتیجه گرفتیم که مدل هیبریدی از مدل شبکه عصبی مصنوعی در همه موارد یعنی از نظر قدرت پیش‌بینی‌کنندگی و صحت بالاتر و از نظر خطای مجذور میانگین پایین‌تر است. یافته‌های پژوهش کاملاً با مطالعات پیشین مطابقت دارد (برای مثال: دریسیتل و اوهنو-ماچادو، ۲۰۰۲:۳۵۴؛ لین، ۲۰۰۹:۸۳۳۳؛ لی و همکاران، ۲۰۱۶:۳۵۱). نتایج تحقیق نتایج این پژوهش پیشنهاد می‌دهند که مدل هیبریدی ANN/LOGISTIC در ارزیابی ریسک اعتباری شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران دقیق‌تر می‌باشد. حداقل این پژوهش نشان می‌دهد که به احتمال بیشتری شرکت‌های دارای ریسک اعتباری، نسبت سودآوری پایین‌تری نسبت به شرکت‌های بدون ریسک اعتباری دارند. همچنین اهرم این شرکت‌ها بالاتر و نسبت‌های فعالیت آنها نسبت به شرکت‌های بدون ریسک اعتباری کمتر می‌باشد به‌علاوه شرکت‌های دارای ریسک اعتباری به احتمال زیاد جوان‌تر و بزرگ‌تر از شرکت‌های بدون ریسک اعتباری می‌باشند. این مطالعه از جهت اینکه مطالعات گذشته در ایران تنها روی روش‌های آماری سنتی متمرکز بوده است حائز توجه می‌باشد. علاوه بر این، پژوهش حاضر ثابت می‌کند که گنجاندن روش‌های آماری سنتی برای مثال رگرسیون لجستیک به ارتقای صحت فناوری‌های هوشمند مثل شبکه‌های عصبی مصنوعی در مدل‌های اعتبارسنجی کمک می‌کند. مدل هیبریدی ANN/LOGISTIC کاربردهای عملی دارد. اعتبارسنجی از حوزه‌های اصلی حسابداری و مالی می‌باشد که فن‌آوری‌های هوشمند در آن به کار گرفته می‌شود استفاده از مدل هیبریدی ANN/LOGISTIC در ارزیابی اعتباری شرکت‌ها همچنین می‌تواند منجر به کاهش کفایت سرمایه بانک‌ها و در نتیجه کاهش نرخ بهره

بانک‌ها شود و اینکه فضای رقابتی را برای بانک‌ها برای جذب مشتریان فراهم می‌نماید. در پایان نتایج فرضیات پژوهش به تفکیک مورد بحث قرار می‌گیرند.

منابع

۱. جعفری اسکندری، میثم، روحی، میلاد. (۱۳۹۶). مدیریت ریسک اعتباری مشتریان بانکی با استفاده از روش ماشین بردار تصمیم بهبودیافته با الگوریتم ژنتیک با رویکرد داده‌کاوی. مدیریت دارایی و تأمین مالی، ۵(۴)، ۱۷-۳۲.
۲. شیرین بخش، شمس‌اله، یوسفی، ندا، قربان زاده، جهانگیر (۱۳۹۰)، بررسی عوامل مؤثر بر احتمال عدم بازپرداخت تسهیلات اعتباری بانک‌ها، مطالعه موردی مشتریان حقوقی بانک توسعه صادرات ایران، دانش مالی تحلیل اوراق بهادار، سال چهارم، شماره چهارم. صص ۱۱۱-۱۳۷.
۳. صداقت‌پرست، الدار، گلزاریان‌پور، سیاوش، غفاری غازانی، حسن. (۱۳۹۴). ارزیابی ریسک اعتباری مشتریان حقوقی با استفاده از شاخص‌های مالی و عملکردی (مطالعه موردی: بانک ملت استان آذربایجان شرقی). فصلنامه مطالعات مالی و بانکداری اسلامی، ۱(پاییز و زمستان)، ۸۴-۵۷.
۴. قاسمی، احمدرضا، دنیایی هریس، طاهره. (۱۳۹۵). اندازه‌گیری ریسک اعتباری مشتریان با رویکرد شبکه عصبی در یکی از بانک‌های دولتی. مجله مهندسی مالی و مدیریت اوراق بهادار، شماره ۲۷، تابستان ۹۵.
۵. محمدی، تیمور، جوهری، هادی. (۱۳۹۷). ارزیابی مدل‌های ریسک اعتباری بانک‌ها با رویکرد ویژگی‌های اخلاقی مشتریان. فصلنامه اخلاق در علوم و فناوری، ۱۲(۱)، ۸-۱.
۶. میرغفوری، سیدحبیب‌اله، امین آشوری، زهره. (۱۳۹۴). ارزیابی ریسک اعتباری مشتریان بانک‌ها. کاوش‌های مدیریت بازرگانی، ۷(۱۳)، ۲۴۷-۲۶۶.
۷. ناجی اصفهانی، سیدعلی، رستگار، محمدعلی. (۱۳۹۷). برآورد ریسک اعتباری مشتریان با استفاده از تحلیل چند بعدی ترجیحات (مطالعه موردی: یک بانک تجاری در ایران). فصلنامه علمی - پژوهشی مدل‌سازی اقتصادی، ۱۲(۴۴)، ۱۴۳-۱۶۱.
8. Abdou, H. A., & Pointon, J. (2011). Credit scoring, statistical techniques and evaluation criteria: A review of the literature. *Intelligent Systems in Accounting, Finance and Management*, 18 (2-3), 59-88.
9. Abdou, H., El-Masry, A., & Pointon, J. (2007). On the applicability of credit scoring models in Egyptian banks. *Banks and Bank Systems*, 2 (1), 4-20.
10. Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23 (4), 589-609.
11. Altman, E. I., & Sabato, G. (2007). Modelling credit risk for SMEs: Evidence from the US market. *Abacus*, 43 (3), 332-357.

12. Angelini, E., di Tollo, G., & Roli, A. (2008). A neural network approach for credit risk evaluation. *The Quarterly Review of Economics and Finance*, 48 (4), 733–755.
13. Arifovic, J., & Gencay, R. (2001). Using genetic algorithms to select architecture of a feedforward artificial neural network. *Physica A: Statistical mechanics and its applications*, 289 (3), 574–594.
14. Baesens, B., Van Gestel, T., Viaene, S., Stepanova, M., Suykens, J., & Vanthienen, J. (2003). Benchmarking state-of-the-art classification algorithms for credit scoring. *Journal of the operational research society*, 54 (6), 627–635.
15. Banasik, J., Crook, J., & Thomas, L. (2001). Scoring by usage. *Journal of the Operational Research Society*, 52 (9), 997–1006.
16. Bellovary, J. L., Giacomino, D. E., & Akers, M. D. (2007). A review of bankruptcy prediction studies: 1930 to present. *Journal of Financial Education*, 33, 1–42.
17. Blanco, A., Delgado, M., & Pegalajar, M. C. (2001). A real-coded genetic algorithm for training recurrent neural networks. *Neural networks*, 14 (1), 93–105.
18. Boyes, W. J., Hoffman, D. L., & Low, S. A. (1989). An econometric analysis of the bank credit scoring problem. *Journal of Econometrics*, 40 (1), 3–14.
19. Chatterjee, S., & Barcun, S. (1970). A nonparametric approach to credit screening. *Journal of the American Statistical Association*, 65 (329), 150–154.
20. Chen, F. L., & Li, F. C. (2010). Combination of feature selection approaches with SVM in credit scoring. *Expert Systems with Applications*, 37 (7), 4 902–4 909.
21. Cole, R. A. (1998). The importance of relationships to the availability of credit. *Journal of Banking and Finance*, 22 (6), 959–977.
22. Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20 (3), 273–297.
23. Crook, J. N., Edelman, D. B., & Thomas, L. C. (2007). Recent developments in consumer credit risk assessment. *European Journal of Operational Research*, 183 (3), 1447–1465.
24. Desai, V. S., Crook, J. N., & Overstreet, G. A., Jr (1996). A comparison of neural networks and linear scoring models in the credit union environment. *European Journal of Operational Research*, 95 (1), 24–37.
25. Dreiseitl, S., & Ohno-Machado, L. (2002). Logistic regression and artificial neural network classification models: A methodology review. *Journal of biomedical informatics*, 35 (5), 352–359.
26. Duh, M. S., Walker, A. M., Pagano, M., & Kronlund, K. (1998). Prediction and cross-validation of neural networks versus logistic regression: Using

- hepatic disorders as an example. *American journal of epidemiology*, 147 (4), 407–413.
27. Etemadi, H., Rostamy, A. A. A., & Dehkordi, H. F. (2009). A genetic programming model for bankruptcy prediction: Empirical evidence from Iran. *Expert Systems with Applications*, 36 (2), 3199–3207.
 28. Ewert, D. C. (1968). Trade-credit management: Selection of accounts receivable using a statistical model. *The Journal of Finance*, 23 (5), 891–892.
 29. Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems. *Annals of Human Genetics*, 7 (2), 179–188.
 30. Hamadani, A. Z., Shalbafzadeh, A., Rezvan, T., & Moghadam, A. (2013). An integrated genetic-based model of naive Bayes networks for credit scoring. *International Journal of Artificial Intelligence & Applications*, 4 (1), 85–103.
 31. Hand, D. J., Oliver, J. J., & Lunn, A. D. (1998). Discriminant analysis when the classes arise from a continuum. *Pattern Recognition*, 31 (5), 641–650.
 32. Harris, T. (2015). Credit scoring using the clustered support vector machine. *Expert Systems with Applications*, 42 (2), 741–750.
 33. Huang, C. L., Chen, M. C., & Wang, C. J. (2007). Credit scoring with a data mining approach based on support vector machines. *Expert systems with applications*, 33 (4), 847–856.
 34. Khashman, A. (2011). Credit risk evaluation using neural networks: Emotional versus conventional models. *Applied Soft Computing*, 11 (8), 5477–5484.
 35. Kozeny, V. (2015). Genetic algorithms for credit scoring: Alternative fitness function performance comparison. *Expert Systems with Applications*, 42 (6), 2998–3004.
 36. Lee, T. H., & Sung-Chang, J. (2000). Forecasting creditworthiness: Logistic vs. artificial neural net. *Journal of Business Forecasting Methods and Systems*, 18 (4), 28–30.
 37. Li, K., Niskanen, J., Kolehmainen, M., & Niskanen, M. (2016). Financial innovation: Credit default hybrid model for SME lending. *Expert Systems with Applications*, 61, 343–355.
 38. Liang, D., Tsai, C. F., & Wu, H. T. (2015). The effect of feature selection on financial distress prediction. *Knowledge-Based Systems*, 73, 289–297.
 39. Lin, S. L. (2009). A new two-stage hybrid approach of credit risk in banking industry. *Expert Systems with Applications*, 36 (4), 8333–8341.
 40. Mahmoudi, N., & Duman, E. (2015). Detecting credit card fraud by modified Fisher discriminant analysis. *Expert Systems with Applications*, 42 (5), 2510–2516.
 41. Mirkin, B. (1996). *Mathematical classification and clustering*. Kluwer Academic Publishers, 74–76.

42. Myers, J. H., & Forgy, E. W. (1963). The development of numerical credit evaluation systems. *Journal of the American Statistical Association*, 58 (303), 799–806.
43. Malhotra, R., & Malhotra, D. K. (2003). Evaluating consumer loans using neural net- works. *Omega*, 31 (2), 83–96.
44. Martens, D., Baesens, B., Van Gestel, T., & Vanthienen, J. (2007). Comprehensible credit scoring models using rule extraction from support vector machines. *European journal of operational research*, 183 (3), 1466–1476.
45. Oreski, S., Oreski, D., & Oreski, G. (2012). Hybrid system with genetic algorithm and artificial neural networks and its application to retail credit risk assessment. *Expert systems with applications*, 39 (16), 12605–12617.
46. Oreski, S., & Oreski, G. (2014). Genetic algorithm-based heuristic for feature selection in credit risk assessment. *Expert systems with applications*, 41 (4), 2052–2064.
47. Orgler, Y. E. (1970). A credit scoring model for commercial loans. *Journal of Money, Credit and Banking*, 2 (4), 435–445.
48. Paliwal, M., & Kumar, U. A. (2009). Neural networks and statistical techniques: A review of applications. *Expert Systems with Applications*, 36 (1), 2–17.
49. Piramuthu, S. (1999). Financial credit-risk evaluation with neural and neurofuzzy systems. *European Journal of Operational Research*, 112 (2), 310–321.
50. Schafer, D. H. (2008). Effect of train length on railroad accidents and a quantitative analysis of factors affecting broken rails. University of Illinois at Urbana-Champaign.
51. Siddiqi, N. (2005). *Credit Risk Scorecards: Developing and Implementing Intelligent Credit Scoring*. Hoboken (New Jersey): John Wiley & Sons.
52. Soydaner, D., & Kocadağlı, O. (2015). Artificial neural networks with gradient learning algorithm for credit scoring. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 44(2), 3-12.
53. Steenackers, A., & Goovaerts, M. (1989). A credit scoring model for personal loans. *Insurance: Mathematics and Economics*, 8 (1), 31–34.
54. Šušteršič, M., Mramor, D., & Zupan, J. (2009). Consumer credit scoring models with limited data. *Expert Systems with Applications*, 36(3), 4736–4744.
55. Tabachnick, B. G., & Fidell, L. S. (2001). *Using multivariate statistics*. Pearson/Allyn. Bacon, Boston.
56. Tsai, C.-F., & Wu, J.-W. (2008). Using neural network ensembles for bankruptcy pre- diction and credit scoring. *Expert Systems with Applications*, 34 (4), 2639–2649.

57. West, D. (2000). Neural network credit scoring models. *Computers and Operations Research*, 27 (11), 1131–1152.
58. Wiginton, J. C. (1980). A note on the comparison of logit and discriminant models of consumer credit behavior. *Journal of Financial and Quantitative Analysis*, 15 (03), 757–770.
59. Yao, X., Crook, J., & Andreeva, G. (2015). Support vector regression for loss given default modelling. *European Journal of Operational Research*, 240 (2), 528–538.
60. Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14 (1), 35–62.
61. Zhao, Z., Xu, S., Kang, B. H., Kabir, M. M. J., Liu, Y., & Wasinger, R. (2015). Investigation and improvement of multi-layer perception neural networks for credit scoring. *Expert Systems with Applications*, 42 (7), 3508–3516.