

ارائه یک مدل طبقه‌بندی ترکیبی هوشمند مبتنی بر شبکه‌های عصبی پرسپترون چندلایه و رگرسیون فازی به منظور تجزیه و تحلیل مسائل امتیازدهی اعتباری

مهدی خاشعی و شیدا تربت *

دانشکده مهندسی صنایع و برنامه‌ریزی سیستم‌ها، دانشگاه صنعتی اصفهان، اصفهان

(دریافت مقاله: ۱۳۹۵/۱۰/۲۹ - دریافت نسخه نهایی: ۱۳۹۶/۰۴/۱۸)

چکیده - بحران‌های مالی موجود در نظام‌های بانکی ناشی از عدم توانایی در مدیریت ریسک‌های اعتباری است. امتیازدهی اعتباری یکی از تکنیک‌های مدیریت ریسک است که ریسک وام‌گیرنده را تحلیل می‌کند. در این مقاله با استفاده از مزایای روش‌های هوش محاسباتی و محاسبات نرم یک روش ترکیبی جدید به منظور بهبود مدیریت ریسک‌های اعتباری ارائه شده است. در روش پیشنهادی، به منظور مدل‌سازی در شرایط عدم قطعیت، پارامترهای شبکه عصبی، شامل وزن‌ها و خطاها، به صورت فازی در نظر گرفته شده‌اند. در این روش، ابتدا سیستم مورد مطالعه با استفاده از شبکه‌های عصبی متامدل‌بندی شده و سپس با به‌کارگیری استنتاجات فازی تصمیم بهینه با بیشترین میزان برتری تعیین خواهد شد. نتایج حاصل از به‌کارگیری روش پیشنهادی بیانگر کارآمدی و دقت بالای این روش در تحلیل مسائل امتیازدهی اعتباری است.

واژه‌های کلیدی: امتیازدهی اعتباری، روش‌های طبقه‌بندی، پرسپترون‌های چندلایه، شبکه‌های عصبی مصنوعی، منطق فازی.

A Hybrid Intelligent Classification Model Based on Multilayer Perceptron Neural Networks and Fuzzy Regression for Credit Scoring Problems

M. Khashei and Sh. Torbat*

Department of Industrial Engineering, Isfahan University of Technology, Isfshsn, Iran.

Abstract: Financial crises in banking systems are due to inability to manage credit risks. Credit scoring is one of the risk management techniques that analyze the borrower's risk. In this paper, using the advantages of computational intelligence as well as soft computing methods, a new hybrid approach is proposed in order to improve credit risk management. In the proposed method, for modeling in uncertainty conditions, parameters of the neural network, including weights and errors, are considered

*: مسئول مکاتبات، پست الکترونیکی: s.torbat@in.iut.ac.ir

in the form of fuzzy numbers. In this method, the underlying system is firstly modeled using neural networks and then, using fuzzy inferences, the optimal decision will be determined with the highest degree of superiority. Empirical results of using the proposed method indicate the efficiency and high accuracy of this method in analyzing credit rating problems.

Keywords: Credit scoring, Classification methods, Multilayer perceptrons (MLPs), Artificial neural networks, Fuzzy logic.

فهرست علائم

وزن فازی شبکه عصبی از نورون i به نورون j	$\tilde{w}_{i,j}$	بایاس شبکه عصبی مربوط به نورون خروجی	b_o
متغیر توضیح‌دهنده t در زمان t	$x_{i,t}$	بایاس شبکه عصبی مربوط به نورون میانی λ	$b_{\lambda,j}$
وقفه t متغیر هدف در زمان t	y_{t-i}	تابع فعال‌سازی شبکه عصبی در لایه خروجی	$F(x)$
متغیر هدف در زمان t	y_t	تابع چگالی احتمال مربوط به متغیر x	$f(x)$
مرکز عدد فازی مربوط به پارامتر λ	α_i	تابع فعال‌سازی شبکه عصبی در لایه میانی	$G(x)$
گسترش عدد فازی مربوط به پارامتر λ	β_i	سطح آستانه مربوط به تابع عضویت متغیر x	$h(x)$
خطای خالص مدل‌سازی در زمان t	ε_t	تابع فازی نوع-ال، دایوس و پرایس برای متغیر x	$L(x)$
تابع عضویت فازی مربوط به اوزان شبکه عصبی	$\mu_{\tilde{w}}(w_{i,j})$	احتمال عضویت یک داده به طبقه A	P_A
		وزن اتصالی شبکه عصبی از نورون i به نورون j	$w_{i,j}$

۱- مقدمه

مورد استفاده قرار می‌گیرند. رقابت فزاینده، کانال‌های فروش الکترونیک و مقررات بانکی فعلی کاتالیزورهای مهمی برای کاربرد سیستم‌های امتیازدهی اتوماتیک بوده‌اند.

امتیازدهی اعتباری نخستین بار همچون ابزاری دم‌دستی برای متعهد ساختن اعتبارات خرد مانند وام‌های رهن مسکن، کارت‌های اعتباری، وام‌های قسطی و اعتبارات تجاری خرد معرفی شد. این مدل‌ها امروزه برای نظارت و هدایت ریسک نکول در کل پرتفوی اعتباری یک نهاد مالی شامل بانک‌ها، بنگاه‌ها، حکومت‌ها، تأمین مالی پروژه‌ها، مؤسسات مالی و غیره مورد استفاده قرار می‌گیرد. مدل‌های امتیازدهی اعتباری صرفاً برای تصویب اعتبار به کار نمی‌روند، بلکه در حوزه‌های دیگر مانند قیمت‌گذاری، ذخیره‌سازی، محاسبه سرمایه نظارتی و اوراق بهادار نیز مورد استفاده قرار می‌گیرند. با توجه به موفقیت گسترده کاربرد امتیازدهی در محیط اعتباری امروزی، مؤسسات مالی نیز استفاده از تکنیک‌های امتیازدهی را بر مبنای طیفی از سایر اهداف تجاری شروع کرده‌اند. برنامه امتیازدهی، ریسک وام‌گیرنده را در لحظه اعطای اعتبار ارزیابی

امتیازدهی اعتباری یک تکنیک مدیریت ریسک اعتباری است که ریسک وام‌گیرنده را تحلیل می‌کند. در معنای اولیه آن، امتیازات اعتباری به هر مشتری متناسب می‌شوند تا سطح ریسک آن را نشان دهند. یک مدل مناسب در حوزه امتیازدهی اعتباری باید قدرت تفکیک میان مشتریان را داشته باشد. این‌گونه از مدل‌ها، به‌طور اساسی متقاضیان را به دو گروه اعتباری خوب و بد تقسیم می‌کند. گروه اعتباری خوب، گروهی هستند که دیون خود را به موقع بازپرداخت می‌کنند و گروه اعتباری بد، گروهی هستند که به احتمال مشخص، دیون آنها نکول خواهد شد [۱]. در گذشته امتیازدهی اعتباری بر اندازه‌گیری این ریسک متمرکز بود که یک مشتری به تعهدات مالی اش عمل نکند و پرداخت معوق داشته باشد. به تازگی، امتیازدهی اعتباری، همین‌طور ریسک زیان و اثر کلی ریسک را نیز دربرمی‌گیرد. تکنیک‌های امتیازدهی، امروزه در سراسر چرخه عمر یک اعتبار به‌عنوان ابزار حامی تصمیم‌گیری یا الگوریتم تصمیم‌گیری اتوماتیک برای طیف وسیعی از مشتریان

می‌کند. وقتی وامی نکول می‌شود، سیستم امتیازدهی برای پشتیبانی از امتیازات وصول شده استفاده و پارامترهای ریسک را به‌روزرسانی می‌کند [۲].

در ادبیات موضوع مرتبط با روش‌های امتیازدهی اعتباری، روش‌های آماری مختلفی از جمله رگرسیون لجستیک [۳] و [۴]، تحلیل جدایش خطی [۵ و ۶]، تحلیل جدایش درجه دوم [۷] و شبکه‌های بیزین [۸ و ۹] به‌منظور ارزیابی مسائل امتیازدهی اعتباری پیشنهاد شده است. روش‌های هوش مصنوعی مانند شبکه‌های عصبی مصنوعی [۱۰ و ۱۱]، ماشین‌های بردار پشتیبان [۱۲]، درخت تصمیم [۱۳] و الگوریتم ژنتیک [۱۴]، به‌عنوان گروهی دیگر از مدل‌های طبقه‌بندی که عملکرد موفقیت‌آمیزی در تحلیل مسائل امتیازدهی اعتباری داشته‌اند، پیشنهاد شده است. اگرچه روش‌های آماری و هوش مصنوعی، روش‌هایی دقیق و کارا محسوب می‌شوند اما هر دو، مدل‌هایی قطعی به‌شمار می‌آیند که در فرایند مدل‌سازی آنها منطق کلاسیک به‌کار گرفته شده است. بنابراین در شرایطی که با پیچیدگی و عدم قطعیت مواجه هستیم مدل‌های کارایی نخواهند بود [۱۵]. از این‌رو در چنین شرایطی مدل‌های پیش‌بینی و طبقه‌بندی فازی از جمله سری‌های زمانی فازی و مدل رگرسیون خطی فازی می‌توانند مناسب باشند، هرچند که کارایی این‌گونه از مدل‌ها نیز همیشه رضایت‌بخش نخواهد بود [۱۶].

بسیاری از محققان بر این باورند که ترکیب مدل‌ها می‌تواند منجر به بهبود کارایی شود. بر این اساس در پژوهش‌های پیشین به‌منظور فائق آمدن بر محدودیت‌های مدل‌های واحد و بهبود کارایی مدل‌های طبقه‌بندی، استفاده از مدل‌های ترکیبی امری رایج و متداول به‌شمار می‌آید. هدف از ترکیب مدل‌ها کاهش میزان ریسک ناشی از استفاده از مدل‌های نامناسب و کسب نتایج کارا است. به‌عبارت دیگر انگیزه اصلی در به‌کارگیری مدل‌های ترکیبی، نتیجه این موضوع است که هر یک از مدل‌هایی که در اینجا گفته شد به‌تنهایی توانایی کافی در تشخیص فرایند تولید داده و

تشخیص ویژگی‌های داده‌ها را ندارد [۱۷]. در سال‌های اخیر مدل‌های طبقه‌بندی ترکیبی بسیاری به‌منظور افزایش دقت و کارایی پیشنهاد شده‌اند که در بخش بعدی به‌طور مختصر به برخی از آنها اشاره خواهد شد.

هدف این مقاله استفاده از مزایای اختصاصی شبکه‌های عصبی مصنوعی و استنتاج فازی به‌منظور ارائه روش ترکیبی جدید، جهت بهبود کیفیت تصمیم‌های مالی در راستای اعطای امتیازات اعتباری به مشتریان در بانک‌ها و مؤسسات مالی و اعتباری است. در روش پیشنهادی، ابتدا سیستم مورد مطالعه با استفاده از شبکه‌های عصبی متامدل‌بندی شده و سپس با به‌کارگیری استنتاج فازی تصمیم و سیاست بهینه با بیشترین میزان برتری تعیین خواهد شد. نتیجه حاصل از به‌کارگیری روش پیشنهادی بیانگر کارآمدی و دقت بالای این روش در تحلیل مسائل امتیازدهی اعتباری است.

در بخش بعدی به ادبیات موضوع مربوطه به‌طور خلاصه اشاره می‌شود. در قسمت سوم خلاصه‌ای از روش شبکه‌های عصبی مصنوعی و رگرسیون فازی شرح داده شده‌اند. مدل ترکیبی شبکه‌های عصبی مصنوعی و رگرسیون فازی در بخش چهارم توضیح داده شده است. در بخش پنجم در رابطه با اطلاعات اعتباری محک کشورهای ژاپن و استرالیا که در این تحقیق مورد استفاده قرار گرفته است، توضیحاتی ارائه شده است. در بخش ششم استفاده از مدل ترکیبی در امتیازدهی اعتباری و طبقه‌بندی مشتریان به دو گروه خوش‌حساب و بدحساب و در نهایت نتیجه‌گیری آورده شده است.

۲- ادبیات موضوع

ادبیات موضوع مربوط به مدل‌های ترکیبی بسیار گسترده بوده و از زمان اولین تحقیقات انجام شده تاکنون، مطالعات فراوانی در این زمینه صورت گرفته است. در این بخش به تعدادی از مدل‌های طبقه‌بندی ترکیبی که از منطق فازی یا شبکه‌های عصبی مصنوعی در تحلیل و ارزیابی بازارهای مالی، به‌ویژه امتیازدهی اعتباری، استفاده شده است به‌طور مختصر اشاره می‌شود.

لی و همکاران [۱۸] با استفاده از شبکه‌های عصبی پس‌انتشار و تحلیل جدایش خطی مدلی برای امتیازدهی اعتباری ارائه کردند. هسیه [۱۹] با هدف طراحی مدلی بهینه برای امتیازدهی اعتباری، یک مدل ترکیبی شامل الگوریتم‌های خوشه‌بندی و شبکه‌های عصبی مصنوعی پیشنهاد داد. هانگ و همکاران [۲۰] با پی‌موند سه مرحله به منظور ساختن مدل‌های امتیازدهی اعتباری مبتنی بر ماشین‌های بردار پشتیبان ترکیبی به ارزیابی امتیازات اعتباری مشتریان از طریق ویژگی‌های آنها پرداختند. لی و همکاران [۲۱] با وارد کردن ترکیبی خطی از توابع کرنل به منظور افزایش قابلیت تفسیر مدل‌های طبقه‌بندی اعتباری، مدلی جایگزین مبتنی بر استراتژی تکاملی برای بهینه‌سازی پارامترها پیشنهاد کردند. کلی‌کیماز و تورکسن [۲۲] سیستم تابع فازی نوع دو را برای مدل‌سازی در شرایط عدم قطعیت با استفاده از الگوریتم‌های تکاملی (ET2FF) معرفی کرده و آن را در تحلیل مسائل دنیای واقع مانند مدل‌سازی بازارهای مالی به کار گرفتند. در این مدل ابتدا، به منظور یافتن ساختارهای پنهان، از خوشه‌بندی فازی بهبود یافته استفاده شده سپس برای بهینه‌سازی فواصل مجموعه‌های فازی، الگوریتم ژنتیک به کار گرفته شده است. چن و لی [۲۳] یک مدل ترکیبی مبتنی بر ماشین‌های بردار پشتیبان پیشنهاد کردند. در این مدل طبقه‌بندی کننده ماشین بردار پشتیبان به ترتیب با استفاده از مدل تحلیل جدایش خطی، درخت تصمیم، F-score و مجموعه راف به عنوان مراحل پیش پردازش با هدف بهینه‌سازی وسعت متغیرها از طریق حذف متغیرهای اضافی و غیرمرتبط، ترکیب شده است. بیژاک و توماس [۲۴] یک مدل دو مرحله‌ای و همزمان پیشنهاد کردند. در این مدل پیشنهادی، کارت‌های اعتباری و طبقه‌بندی به وسیله درختان مدل لجستیک به طور همزمان بهینه می‌شوند.

کیم و هان [۲۵] یک روش ترکیبی از نقشه‌های خودسازمان‌ده (SOM) و استنتاج مبتنی بر مورد (CBR) برای پیش‌بینی میزان اوراق قرضه شرکتی پیشنهاد کردند. پارک و هان [۲۶] با استفاده از روش‌های تحلیل سلسله مراتبی در

استنتاج مبتنی بر مورد به عنوان ابزاری برای وزن‌دهی متغیرها، باعث بهبود عملکرد قابلیت پیش‌بینی مدل استنتاج مبتنی بر مورد در پیش‌بینی نرخ شکست کسب و کار شدند. آهن و کیم [۲۷] با استفاده از الگوریتم ژنتیک در مدل استنتاج مبتنی بر مورد، یک رویکرد ترکیبی جدید ارائه و آن را در پیش‌بینی ورشکستگی شرکت‌های بزرگ به کار گرفتند. در این رویکرد، الگوریتم ژنتیک به طور همزمان عملیات بهینه‌سازی وزن متغیرها و انتخاب نمونه برای مدل استنتاج مبتنی بر مورد را انجام می‌دهد. کاپوتورتی و باربانرا [۲۸] یک متدولوژی ترکیبی برای مسائل طبقه‌بندی پیشنهاد کردند. آنها از مدل خود که مبتنی بر نظریه مجموعه‌های راف، ارزیابی جزئی احتمال شرطی و مجموعه‌های فازی بود برای تحلیل امتیازدهی اعتباری استفاده کردند. آکوک [۲۹] در مطالعه‌ای به مقایسه مدل‌های رایج اقتصادسنجی، شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) برای تحلیل امتیازدهی اعتباری پرداخت. وی به این نتیجه دست یافت که سیستم استنتاج عصبی-فازی تطبیقی به جهت ارائه تفسیری دقیق از فرایند تصمیم‌گیری دارای کارایی بالاتری نسبت به شبکه عصبی مصنوعی و دیگر مدل‌های سنتی اقتصادسنجی است.

یو و همکاران [۳۰] در پژوهش خود با استفاده از یک مدل هوشمند مبتنی بر تصمیم‌گیری گروهی فازی در حوزه پشتیبانی تصمیم‌گیری‌های مالی چندمعیاره به ارزیابی امتیازدهی اعتباری پرداختند. در مدل پیشنهادی تعدادی از تکنیک‌های هوش مصنوعی برای تحلیل و ارزیابی سطح ریسک مشتری تحت معیارهای از پیش تعیین شده به کار گرفته شدند. چن و همکاران [۳۱] با استفاده از روش ترکیبی ماشین بردار پشتیبان به ارزیابی مسائل امتیازدهی اعتباری پرداختند. روش پیشنهادی، مبتنی بر سه استراتژی است: ۱) استفاده از دسته‌بندی و درخت رگرسیون (CART) برای انتخاب متغیرهای ورودی، ۲) استفاده از رگرسیون چند متغیره تطبیقی (MARS) برای انتخاب متغیرهای ورودی و ۳) استفاده از جستجوی شبکه برای

موارد غیرخطی متعدد در داده‌ها بوده و یک چارچوب محاسبه‌ای انعطاف‌پذیر برای دامنه وسیعی از مسائل غیرخطی هستند. شبکه‌های عصبی چندلایه پیشخور با یک لایه مخفی یکی از پرکاربردترین مدل‌های شبکه‌های عصبی هستند [۳۷]. این گونه از مدل‌ها از سه لایه پردازش ساده اطلاعات متصل به هم تشکیل شده‌اند. رابطه بین خروجی (y_t) و ورودی‌ها (y_{t-1}, \dots, y_{t-p}) به صورت زیر است:

$$y_t = b_0 + \sum_{j=1}^Q w_{j0} \cdot g(b_{0j} + \sum_{i=1}^P w_{ij} \cdot y_{t-i}) + \varepsilon_t \quad (1)$$

به طوری که w_j و w_i پارامترهای مدل بوده که اغلب وزن‌های اتصالی نامیده می‌شوند، P تعداد گره‌های ورودی و Q تعداد گره‌های مخفی هستند.

۲-۳- مدل رگرسیون فازی

مدل‌های کلاسیک از مفهوم عبارت خطا استفاده می‌کنند. به عبارت دیگر تخمین‌های این گونه از مدل‌ها مقادیر دقیقی بوده و شامل جمله خطا نمی‌شوند. این همان مفهوم پایه‌ای رگرسیون فازی است که توسط تاناکا [۳۸] پیشنهاد شده است. مفهوم اساسی رگرسیون فازی این است که جمله خطا از باقی‌مانده‌های بین مقادیر تخمین زده شده و مقادیر اصلی تولید نمی‌شوند، بلکه در عدم قطعیت پارامترهای مدل و امکان توزیع در ارتباط با مشاهدات حقیقی به کار گرفته می‌شوند. یک مدل رگرسیون خطی فازی در حالت کلی به صورت زیر است:

$$\tilde{Y} = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + \dots + \tilde{\beta}_n x_n = \sum_{i=1}^n \tilde{\beta}_i x_i = [X] [\tilde{\beta}] \quad (2)$$

به طوری که $[X]$ بردار متغیرهای مستقل، علامت پریم "" عملگر ترانزپوز، n تعداد متغیرها و $\tilde{\beta}_i$ مجموعه‌های فازی بیانگر i -امین پارامتر مدل است. این اعداد فازی (پارامترهای $\tilde{\beta}_i$) به شکل اعداد فازی نوع ال، دوبویس و پراد $(\alpha_i, f_i)_L$ با توزیع احتمال به صورت زیر هستند:

$$\mu_{\tilde{\beta}_i}(\beta_i) = L \left\{ \left(\alpha_i - \frac{\beta_i}{C} \right) \right\} \quad (3)$$

بهینه‌سازی پارامترهای مدل. نتایج حاکی از آن است که مدل ترکیبی پیشنهادی نه تنها نرخ طبقه‌بندی بهتری دارد، بلکه دارای خطای نوع دوم کمتری نسبت به هر یک از مدل‌های مذکور به تنهایی است. لی و چوی [۳۲] در پژوهش خود با استفاده از شبکه‌های عصبی پس‌انتشار و تجزیه و تحلیل چند متغیره، با انتخاب متغیرهای مستقل مناسب به پیش‌بینی ورشکستگی پرداختند. زائو و همکاران [۳۳] در تحقیق خود با استفاده از شبکه عصبی پرسپترون چندلایه و به‌کارگیری روش جدیدی به نام انتخاب تصادفی میانگین، با رویکرد بهینه‌سازی توزیع داده‌ها، به بهبود مدل‌های امتیازدهی اعتباری پرداختند. سون و همکاران [۳۴] با استفاده از متغیرهای بیانی و به‌کارگیری رگرسیون لجستیک فازی به مدل‌سازی مسائل امتیازدهی اعتباری پرداختند. آلاراج و ابود [۳۵] به منظور بهبود دقت مدل‌سازی خود، یک مدل امتیازدهی اعتباری ترکیبی ارائه کردند. در این مدل روش‌های ترکیبی هم در فاز پیش‌پردازش داده‌ها و هم در فاز طبقه‌بندی مشتریان به کار گرفته شدند. نتو و همکاران [۳۶] با استفاده از ابزارهای هوش محاسباتی و مدل‌های کلاسیک یک چارچوب محاسبه‌ای مبتنی بر رویکردهای مدل‌محور به منظور پیش‌پردازش حجم انبوه اطلاعات استفاده کردند.

۳- شبکه‌های عصبی مصنوعی و منطق فازی

همان‌گونه که پیش‌تر نیز اشاره شد، در این مقاله به منظور بهبود کیفیت تصمیم‌گیری‌های مالی و مدل‌سازی پیچیدگی‌ها و عدم قطعیت‌های موجود در مسئله از ابزارهای هوش محاسباتی و روش‌های محاسبات نرم به صورت همزمان استفاده شده است. در ادامه به طور مختصر به توضیح هر یک پرداخته شده است.

۱-۳- شبکه‌های عصبی مصنوعی

ابزارهای هوش محاسباتی همچون شبکه‌های عصبی مصنوعی یکی از جمله روش‌های غیرخطی هستند که قادر به تخمین

۴- فرمول بندی مدل پیشنهادی

به قسمی که $\tilde{X}_{t,j} = g(\tilde{w}_{\cdot,j} + \sum_{i=1}^p \tilde{w}_{i,j} \cdot y_{t-i})$ است. وزن های اتصال بین لایه ورودی و لایه میانی در این معادله به صورت اعداد فازی مثلثی $\tilde{w}_{i,j} = (a_{i,j}, b_{i,j}, c_{i,j})$ مطابق زیر است:

$$\mu_{\tilde{w}_{i,j}}(w_{i,j}) = \begin{cases} \frac{1}{b_{i,j} - a_{i,j}}(w_{i,j} - a_{i,j}) & a_{i,j} \leq w_{i,j} \leq b_{i,j}, \\ \frac{1}{b_{i,j} - c_{i,j}}(w_{i,j} - c_{i,j}) & b_{i,j} \leq w_{i,j} \leq c_{i,j}, \\ 0 & \text{otherwise,} \end{cases} \quad (6)$$

به طوری که $\mu_{\tilde{w}}(w_{i,j})$ تابع عضویت یک مجموعه فازی است که با پارامترهای $w_{i,j}$ مشخص می شود. حال با استفاده از اصل گسترش، تابع عضویت $\tilde{X}_{t,j} = g(\tilde{w}_{\cdot,j} + \sum_{i=1}^p \tilde{w}_{i,j} \cdot y_{t-i})$ مطابق زیر خواهد بود [۳۹]:

$$\mu_{\tilde{X}_{t,j}}(X_{t,j}) = \begin{cases} \frac{\left(X_{t,j} - g\left(\sum_{i=1}^p a_{i,j} y_{t,i} \right) \right)}{g\left(\sum_{i=1}^p b_{i,j} y_{t,i} \right) - g\left(\sum_{i=1}^p a_{i,j} y_{t,i} \right)} & \text{if } g\left(\sum_{i=1}^p a_{i,j} y_{t,i} \right) \leq X_{t,j} \leq g\left(\sum_{i=1}^p b_{i,j} y_{t,i} \right), \\ \frac{\left(X_{t,j} - g\left(\sum_{i=1}^p c_{i,j} y_{t,i} \right) \right)}{g\left(\sum_{i=1}^p b_{i,j} y_{t,i} \right) - g\left(\sum_{i=1}^p c_{i,j} y_{t,i} \right)} & \text{if } g\left(\sum_{i=1}^p b_{i,j} y_{t,i} \right) \leq X_{t,j} \leq g\left(\sum_{i=1}^p c_{i,j} y_{t,i} \right), \\ 0 & \text{otherwise,} \end{cases} \quad (7)$$

به طوری که $y_{t,i} = y_{t-i}$ ($t=1,2,\dots,k$, $i=1,2,\dots,p$) و $y_{t,i} = 1$ ($t=1,2,\dots,k$, $i=0$) فازی مثلثی $\tilde{X}_{t,j}$ با تابع عضویتی مطابق رابطه (۷) و پارامترهای فازی مثلثی \tilde{w}_j تابع عضویت

$$\tilde{y}_t = f(\tilde{w}_{\cdot} + \sum_{j=1}^q \tilde{w}_j \cdot \tilde{X}_{t,j}) = f\left(\sum_{j=0}^q \tilde{w}_j \cdot \tilde{X}_{t,j}\right) \quad \text{زیر خواهد بود:}$$

شبکه های عصبی پرسپترون چندلایه ابزارهای محاسبه انعطاف پذیر با درجه بالایی از کارایی هستند و برای طیف وسیعی از مسائل طبقه بندی به کار گرفته می شوند. شبکه های عصبی پرسپترون چندلایه دارای ویژگی های متمایزی هستند که آنها را به ابزاری ارزشمند و قوی در حوزه مسائل طبقه بندی تبدیل کرده است. از جمله مهم ترین این ویژگی ها می توان به اطلاعات محور بودن و حالت خود تطبیقی این روش ها اشاره کرد. با وجود ویژگی های گفته شده، این مدل ها دارای محدودیت تعداد زیاد داده های گذشته برای به دست آوردن نتایج دقیق هستند [۳۹]. در صورتی که امروزه به علت عدم قطعیت محیط و توسعه سریع تکنولوژی، باید موقعیت های آینده را با استفاده از داده های کم و در بازه های زمانی کوتاه مدت تحلیل و ارزیابی کرد. بنابراین نیازمند روش هایی هستیم که به داده های کمتری نیاز داشته و در این گونه از شرایط نیز کارا باشند. هدف این روش ترکیبی بهره مندی از ویژگی های رگرسیون فازی و برطرف کردن محدودیت نیاز به داده های زیاد در روش شبکه عصبی به منظور ارزیابی ریسک اعتباری است.

پارامترهای شبکه های عصبی مقادیر قطعی هستند $(w_j (j=0,1,2,\dots,q) \text{ و } w_{i,j} (i=0,1,2,\dots,p \ j=1,2,\dots,q))$ در صورتی که در روش جدید به جای به کارگیری این مقادیر قطعی، پارامترهای شبکه به صورت اعداد فازی در نظر گرفته شده اند. $(\tilde{w}_j (j=0,1,2,\dots,q) \text{ و } \tilde{w}_{i,j} (i=0,1,2,\dots,p \ j=1,2,\dots,q))$ مدل ترکیبی با پارامترهای فازی به صورت زیر است:

$$\tilde{y}_t = f\left(\tilde{w}_{\cdot} + \sum_{j=1}^q \tilde{w}_j \cdot g\left(\tilde{w}_{\cdot,j} + \sum_{i=1}^p \tilde{w}_{i,j} \cdot y_{t-i}\right)\right), \quad (4)$$

به قسمی که y_t مشاهدات، $\tilde{w}_{i,j} (i=0,1,2,\dots,p \ j=1,2,\dots,q)$ و $\tilde{w}_j (j=0,1,2,\dots,q)$ اعداد فازی و f و g به ترتیب توابع فعال سازی لایه میانی و لایه خروجی هستند. با جای گذاری معادله فوق به صورت زیر تبدیل می شود:

$$\tilde{y}_t = f\left(\tilde{w}_{\cdot} + \sum_{j=1}^q \tilde{w}_j \cdot \tilde{X}_{t,j}\right) = f\left(\sum_{j=0}^q \tilde{w}_j \cdot \tilde{X}_{t,j}\right), \quad (5)$$

$$\text{Min } \sum_{t=1}^k \sum_{j=1}^q \left(f_j g \left(\sum_{i=1}^p c_{i,j} y_{t,i} \right) \right) - \left(d_j g \left(\sum_{i=1}^p a_{i,j} y_{t,i} \right) \right)$$

$$\text{Subject to } \begin{cases} \frac{-B_1}{\sqrt{A_1}} + \left[\left(\frac{B_1}{\sqrt{A_1}} \right)^{\gamma} - \frac{C_1 - f^{-1}(y_t)}{A_1} \right]^{\frac{1}{\gamma}} \leq h \\ \text{if } C_1 \leq f^{-1}(y_t) \leq C_{\gamma}, \text{ for } t=1,2,\dots,k, \\ \frac{B_{\gamma}}{\sqrt{A_{\gamma}}} + \left[\left(\frac{B_{\gamma}}{\sqrt{A_{\gamma}}} \right)^{\gamma} - \frac{C_{\gamma} - f^{-1}(y_t)}{A_{\gamma}} \right]^{\frac{1}{\gamma}} \leq h \\ \text{if } C_{\gamma} \leq f^{-1}(y_t) \leq C_{\gamma}, \text{ for } t=1,2,\dots,k, \end{cases}$$

(9)

در نهایت خروجی مدل به صورت فازی و پیوسته است در حالی که در مسائل طبقه بندی خروجی به صورت غیر فازی و گسسته است. بنابراین برای به کارگیری مدل پیشنهادی در مسائل طبقه بندی نیازمند بهبود و تعدیل مدل هستیم. برای این منظور، در مرحله اول به هر طبقه یک مقدار عددی اطلاق می شود سپس احتمال عضویت خروجی در هر طبقه مطابق زیر محاسبه می شود:

$$P_A = 1 - P_B = \frac{\int_{-\infty}^m f(x) dx}{\int_{-\infty}^{+\infty} f(x) dx} = 1 - \frac{\int_m^{+\infty} f(x) dx}{\int_{-\infty}^{+\infty} f(x) dx} \quad (10)$$

به قسمی که P_A و P_B به ترتیب احتمال عضویت در هر یک از طبقه های A و B است. در نهایت یک نمونه به طبقه ای منسوب می شود که خروجی آن دارای احتمال بزرگ تری باشد. همان طور که قبلاً بیان شد، در مدل پیشنهادی خروجی به صورت فازی است بنابراین بهتر است برای هر طبقه مقادیر عددی بزرگ در نظر گرفته شود تا مدل نسبت به تغییرات در ورودی حساسیت بیشتری داشته باشد.

۵- مجموعه اطلاعات اعتباری محک

در این بخش به منظور نمایش تناسب و اثربخشی مدل پیشنهادی برای طبقه بندی داده های مالی از مجموعه ای از اطلاعات اعتباری مربوط به کشورهای ژاپن و استرالیا استفاده شده است. توضیح مختصری در رابطه با هر یک از این مجموعه اطلاعات در قسمت

$$\mu_{\tilde{Y}}(y_t) \cong \begin{cases} \frac{-B_1}{\sqrt{A_1}} + \left[\left(\frac{B_1}{\sqrt{A_1}} \right)^{\gamma} - \frac{C_1 - f^{-1}(y_t)}{A_1} \right]^{\frac{1}{\gamma}} \\ \text{if } C_1 \leq f^{-1}(y_t) \leq C_{\gamma}, \\ \frac{B_{\gamma}}{\sqrt{A_{\gamma}}} + \left[\left(\frac{B_{\gamma}}{\sqrt{A_{\gamma}}} \right)^{\gamma} - \frac{C_{\gamma} - f^{-1}(y_t)}{A_{\gamma}} \right]^{\frac{1}{\gamma}} \\ \text{if } C_{\gamma} \leq f^{-1}(y_t) \leq C_{\gamma}, \\ 0 \\ \text{otherwise,} \end{cases} \quad (8)$$

به قسمی که:

$$A_1 = \sum_{j=1}^q (e_j - d_j) \cdot \left(\begin{array}{c} g \left(\sum_{i=1}^p b_{i,j} \cdot y_{t,i} \right) \\ -g \left(\sum_{i=1}^p a_{i,j} \cdot y_{t,i} \right) \end{array} \right),$$

$$B_1 = \sum_{j=1}^q \left(d_j \cdot \left(\begin{array}{c} g \left(\sum_{i=1}^p b_{i,j} \cdot y_{t,i} \right) \\ -g \left(\sum_{i=1}^p a_{i,j} \cdot y_{t,i} \right) \end{array} \right) + g \left(\sum_{i=1}^p a_{i,j} \cdot y_{t,i} \right) \cdot (e_j - d_j) \right),$$

$$A_{\gamma} = \sum_{j=1}^q (f_j - e_j) \cdot \left(\begin{array}{c} g \left(\sum_{i=1}^p c_{i,j} \cdot y_{t,i} \right) \\ -g \left(\sum_{i=1}^p b_{i,j} \cdot y_{t,i} \right) \end{array} \right),$$

$$B_{\gamma} = \sum_{j=1}^q \left(f_j \cdot \left(\begin{array}{c} g \left(\sum_{i=1}^p c_{i,j} \cdot y_{t,i} \right) \\ -g \left(\sum_{i=1}^p b_{i,j} \cdot y_{t,i} \right) \end{array} \right) + g \left(\sum_{i=1}^p c_{i,j} \cdot y_{t,i} \right) \cdot (f_j - e_j) \right),$$

$$C_1 = \sum_{j=1}^q \left(d_j \cdot g \left(\sum_{i=1}^p a_{i,j} \cdot y_{t,i} \right) \right)$$

$$C_{\gamma} = \sum_{j=1}^q \left(f_j \cdot g \left(\sum_{i=1}^p c_{i,j} \cdot y_{t,i} \right) \right),$$

$$C_{\gamma} = \sum_{j=1}^q \left(e_j \cdot g \left(\sum_{i=1}^p b_{i,j} \cdot y_{t,i} \right) \right),$$

حال با در نظر گرفتن سطح آستانه h برای میزان توابع عضویت تمامی مشاهدات یک مدل برنامه ریزی غیر خطی مطابق با رابطه زیر به دست می آید:

جدول ۱- مجموعه اطلاعات اعتباری ژاپن

ویژگی‌ها	نوع	مقادیر	مقادیر (پیشین)
۱	دسته‌ای	۰ و ۱	a,b
۲	عددی	۸۰/۲۵-۱۳/۷۵	۸۰/۲۵-۱۳/۷۵
۳	عددی	۰-۲۸	۰-۲۸
۴	دسته‌ای	۱ و ۲ و ۳	u,y,i
۵	دسته‌ای	۱ و ۲ و ۳	g,p,gg
۶	دسته‌ای	۱ و ۲ و ۳ و... و ۱۴	ff,d,i,k,j,aa,m,c,w,,q,r,cc,x
۷	دسته‌ای	۱ و ۲ و ۳ و... و ۹	ff,dd,j,bb,v,n,o,h,z
۸	عددی	۰-۲۸/۵	۰-۲۸/۵
۹	دسته‌ای	۰ و ۱	t,f
۱۰	دسته‌ای	۰ و ۱	t,f
۱۱	عددی	۰-۶۷	۰-۶۷
۱۲	دسته‌ای	۰ و ۱	t,f
۱۳	دسته‌ای	۱ و ۲ و ۳	s,g,p
۱۴	عددی	۰-۲۰۰۰	۰-۲۰۰۰
۱۵	عددی	۰-۱۰۰۰۰۰	۰-۱۰۰۰۰۰
کلاس	گسسته	۰ و ۱	- و +





بعدی ذکر شده است. این مجموعه اطلاعات، به‌علت دارا بودن ترکیب مناسبی از ویژگی‌ها که همزمان شامل ارزش‌های عددی کوچک و ارزش‌های عددی بزرگ هستند مورد توجه بسیاری از محققان در حوزه مدیریت مالی قرار گرفته‌اند.

۱-۵- مجموعه اطلاعات اعتباری ژاپن

به‌طور کلی این مجموعه اطلاعات شامل ۶۹۰ مشاهده است. در این بین ۳۰۷ نمونه (حدود ۴۴/۵ درصد) از افراد مورد مطالعه در زمره مشتریان خوش‌حساب و ۳۸۳ نمونه (حدود ۵۵/۵ درصد) در زمره مشتریان بدحساب قرار دارند. این مجموعه داده در مجموع شامل ۳۷ مقدار گم شده است. در این مقاله تمامی این ۳۷ مشاهده از مجموعه داده‌های اصلی حذف شده‌اند. مجموعه داده جدید شامل ۶۵۳ مشاهده است که ۳۵۷ مورد از آنها در زمره مشتریان خوش‌حساب و ۲۹۶ مورد در

زمره مشتریان بدحساب قرار می‌گیرند. همچنین این مجموعه اطلاعات شامل ۱۵ ویژگی است که ۹ مورد از این ویژگی‌ها از نوع دسته‌ای و ۶ مورد از آنها به‌صورت عددی هستند. لازم به‌ذکر است به‌دلیل محرمانه بودن و محافظت از اطلاعات، از بیان دقیق نام ویژگی‌ها و ارزش آنها به‌صورت مستقیم خودداری شده است. خلاصه‌ای از اطلاعات مورد استفاده در جدول (۱) قابل مشاهده است.

داده‌ها به‌صورت تصادفی به دو دسته، داده‌های آموزش و داده‌های تست، تقسیم‌بندی شده‌اند. از بین آنها ۵۰ درصد داده‌ها مربوط به آموزش و ۵۰ درصد مابقی مربوط به تست مدل هستند. نمودارهایی از توزیع دوبعدی از تقابل هر دو ویژگی رسم شده است که در شکل (۱) نمودارهای مربوط به تقابل ویژگی‌های (A_2, A_3) ، (A_2, A_8) ، (A_3, A_8) و (A_{14}, A_{15}) به‌عنوان نمونه قابل مشاهده است.



شکل ۱- توزیع دو بعدی از ویژگی‌های کارت‌های اعتباری ژاپن

جدول ۲- مجموعه اطلاعات اعتباری استرالیا

ویژگی‌ها	نوع	مقادیر	مقادیر (پیشن)
۱	گسسته	۰ و ۱	a,b
۲	پیوسته	۸۰/۲۵-۱۳/۷۵	۸۰/۲۵-۱۳/۷۵
۳	پیوسته	۰-۲۸	۰-۲۸
۴	گسسته	۱ و ۲ و ۳	p,g,gg
۵	گسسته	۱ و ۲ و ۳ و... و ۱۴	ff,d,i,k,j,aa,m,c,w,e,q,r,cc,x
۶	گسسته	۱ و ۲ و ۳ و... و ۹	ff,dd,j,bb,v,n,o,h,z
۷	پیوسته	۰-۲۸/۵	۰-۲۸/۵
۸	گسسته	۰ و ۱	t,f
۹	گسسته	۰ و ۱	t,f
۱۰	پیوسته	۰-۶۷	۰-۶۷
۱۱	گسسته	۰ و ۱	t,f
۱۲	گسسته	۱ و ۲ و ۳	s,g,p
۱۳	پیوسته	۰-۲۰۰۰	۰-۲۰۰۰
۱۴	پیوسته	۰-۱۰۰۰۰۰	۰-۱۰۰۰۰۰
کلاس	گسسته	۰ و ۱	- و +

۲-۵- مجموعه اطلاعات اعتباری استرالیا





به‌طور کلی این مجموعه اطلاعات شامل ۶۹۰ مشاهده و ۱۴ ویژگی است. ۸ مورد از این ویژگی‌ها دارای مقادیر گسسته و شش مورد دارای مقادیر پیوسته هستند. در این بین ۳۰۷ نمونه (حدود ۴۴/۵ درصد) از افراد مورد مطالعه در زمره مشتریان خوش حساب و ۳۸۳ مورد (حدود ۵۵/۵ درصد) در زمره مشتریان بدحساب قرار دارند. خلاصه‌ای از اطلاعات مورد استفاده در جدول (۲) قابل مشاهده است.

داده‌ها به‌صورت تصادفی به دو دسته، داده‌های آموزش و داده‌های تست، تقسیم‌بندی شده‌اند. از بین آنها ۵۰ درصد داده‌ها مربوط به آموزش و ۵۰ درصد مابقی مربوط به تست مدل هستند. نمودارهایی از توزیع دوبعدی از تقابل هر دو ویژگی رسم شده است که در شکل (۲) نمودارهای مربوط به تقابل ویژگی‌های (A_2, A_3) ، (A_2, A_7) ، (A_3, A_{10}) و (A_2, A_{10}) به‌عنوان نمونه قابل مشاهده است.

۲-۶- به‌کارگیری مدل پیشنهادی در تحلیل امتیازدهی

اعتباری

در این قسمت کارایی مدل ترکیبی پیشنهادی، با استفاده از اطلاعات اعتباری کشورهای ژاپن و استرالیا، در تحلیل امتیازدهی اعتباری نشان داده شده است. در مرحله اول به‌منظور دستیابی به بهترین ساختار شبکه عصبی مبتنی بر مفهوم پرسپترون‌های چند لایه [۳۶]، با استفاده از نرم‌افزار 7 MATLAB، شبکه‌های عصبی با ساختارهای مختلف از لحاظ کارایی با یکدیگر مقایسه شده‌اند. در نهایت شبکه ایده‌آل مربوط به اطلاعات اعتباری کشور ژاپن، شبکه‌ای متشکل از ۱۵ نورون ورودی، ۱۶ نورون میانی و یک نورون خروجی (به‌صورت $N^{(15-16-1)}$) و شبکه ایده‌آل مربوط به اطلاعات اعتباری کشور استرالیا، شبکه‌ای متشکل از ۱۴ نورون ورودی، ۱۴ نورون میانی و یک نورون خروجی (به‌صورت $N^{(14-14-1)}$) بوده است. هنگامی که ساختار بهینه تعیین شد، شبکه به‌وسیله الگوریتم پس‌انتشار در ۱۰۰ تکرار آموزش دیده، سپس در مرحله



شکل ۲- توزیع دو بعدی از ویژگی‌های کارت‌های اعتباری استرالیا

جدول ۳- نرخ طبقه‌بندی نادرست در هر مدل

نرخ طبقه‌بندی نادرست (%)		مدل
اطلاعات اعتباری استرالیا	اطلاعات اعتباری ژاپن	
۱۴/۰	۱۳/۸	تحلیل جدایش خطی (LDA) ^۱
۱۹/۹	۱۵/۶	تحلیل جدایش درجه دوم (QDA) ^۲
۱۴/۲	۱۳/۸	Kامین نزدیک‌ترین همسایه (KNN) ^۳
۲۲/۵	۱۳/۸	ماشین‌های بردار پشتیبان (SVM) ^۴
۱۲/۳	۱۱/۴	شبکه‌های عصبی مصنوعی (ANN) ^۵
۱۱/۷	۱۰/۸	سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)
۱۰/۹	۹/۷	مدل ترکیبی پیشنهادی

جدول ۴- میزان بهبود مدل پیشنهادی در مقایسه با سایر مدل‌ها

میزان بهبود (%)		مدل
اطلاعات اعتباری استرالیا	اطلاعات اعتباری ژاپن	
۲۲/۱۴	۲۹/۷۱	تحلیل جدایش خطی (LDA)
۴۵/۲۳	۳۷/۸۲	تحلیل جدایش درجه دوم (QDA)
۲۳/۲۴	۲۹/۷۱	Kامین نزدیک‌ترین همسایه (KNN)
۵۱/۵۶	۲۹/۷۱	ماشین‌های بردار پشتیبان (SVM)
۱۱/۳۸	۱۴/۹۱	شبکه‌های عصبی مصنوعی (ANN)
۶/۸۳	۱۰/۱۸	سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)

دوم حداقل ابهام در پارامترهای فازی با در نظر گرفتن سطح آستانه $h=0$ ، برای به دست آوردن پارامترهای فازی با حداقل پهنای استفاده از معادله (۹)، تعیین شده است. نرخ طبقه‌بندی نادرست در هر مدل و درصد بهبود مدل پیشنهادی (با در نظر گرفتن $h=0$)، در مقایسه با سایر مدل‌های طبقه‌بندی در ارزیابی اطلاعات، به ترتیب در جدول‌های (۳) و (۴) آورده شده است. همان‌طور که نتایج به دست آمده از جدول‌های بالا نشان می‌دهند، در تحلیل اعتباری اطلاعات مربوط به کشور ژاپن مدل پیشنهادی ما، با ۹/۷ درصد خطا در نرخ طبقه‌بندی نادرست و ایجاد ۱۴/۹۱ درصد بهبود در ارزیابی اطلاعات نسبت به مدل پرسپترون چندلایه سنتی، عملکرد بالایی خود را نمایان می‌سازد. به علاوه مدل پیشنهادی به ترتیب منجر به ۲۹/۷۱، ۳۷/۸۲، ۲۹/۷۱

۲۹/۷۱ و ۱۰/۱۸ درصد بهبود نسبت به مدل‌های تحلیل جدایش خطی $(c=0)$ ، تحلیل جدایش درجه دوم $(c=0)$ ، Kامین نزدیک‌ترین همسایه $(K=5)$ ، ماشین‌های بردار پشتیبان $(c=0)$ و سیستم استنتاج فازی-عصبی تطبیقی در ارزیابی اطلاعات شده است. به طور مشابه، مدل پیشنهادی در تحلیل اطلاعات اعتباری مربوط به کشور استرالیا با ۱۰/۹ درصد، دارای کمترین میزان خطا در مقایسه با سایر مدل‌ها است. همچنین این مدل ترکیبی به ترتیب باعث ۲۲/۱۴، ۴۵/۲۳، ۲۳/۲۴، ۵۱/۵۶، ۱۱/۳۸ و ۶/۸۳ درصد بهبود نسبت به مدل‌های تحلیل جدایش خطی $(c=0)$ ، تحلیل جدایش درجه دوم $(c=0)$ ، Kامین نزدیک‌ترین همسایه $(K=13)$ ، ماشین‌های بردار پشتیبان $(c=1)$ ، شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی-عصبی

تطبیقی در ارزیابی اطلاعات شده است.

پیشنهاد شده است. در روش پیشنهادی، به منظور مدل‌سازی بهتر بازارهای مالی در شرایط عدم قطعیت، پارامترهای شبکه عصبی پرسپترون چندلایه، شامل وزن‌ها و خطاها، به صورت پارامترهای فازی در نظر گرفته شده‌اند. در این روش ابتدا سیستم مورد مطالعه با استفاده از شبکه‌های عصبی متامدل‌بندی شده و سپس با به‌کارگیری استنتاج فازی، تصمیم و سیاست بهینه با بیشترین میزان برتری تعیین خواهد شد. مدل پیشنهادی بر خلاف مدل‌های تحلیل جدایش خطی و درجه دوم، فاقد هرگونه فرض شده‌هایی از جمله وجود ارتباط بین متغیرهای مستقل و وابسته است. همچنین این مدل بر خلاف طبقه‌بندی کننده K-امین نزدیک‌ترین همسایه نیازمند ذخیره‌سازی داده‌های آموزش نیست. ماشین‌های بردار پشتیبان نیازمند تعیین پارامتر جریمه و تابع کرنل هستند در صورتی که در مدل پیشنهادی بدون تنظیم این پارامترها، تنها با تکیه بر روند آموزش، طبقه‌بندی کننده نهایی تعیین می‌شود و در نهایت بر خلاف پرسپترون‌های چندلایه، برای دستیابی به نتایج کارا نیازمند حجم زیادی از اطلاعات نیست. نتیجه حاصل از به‌کارگیری روش پیشنهادی بیانگر کارآمدی و دقت بالای این روش نسبت به سایر مدل‌های طبقه‌بندی آماری و هوشمند در تحلیل مسائل امتیازدهی اعتباری است.

۷- نتیجه‌گیری

در سال‌های اخیر تجزیه و تحلیل ریسک اعتباری به‌عنوان یکی از حوزه‌های مهم تحقیقاتی در زمینه مدیریت مالی شناخته شده است. مدیریت ریسک و امتیازدهی اعتباری یکی از تکنیک‌های مهم و تأثیرگذار در ارزیابی ریسک اعتباری و یکی از حوزه‌های کاربردی اصلی مسائل طبقه‌بندی، مبتنی بر جداسازی کارت‌های اعتباری مشتریان و تفکیک آنها به دو گروه اعتباری خوب و بد است. اعطای اعتبار به مشتریان نیازمند تجزیه و تحلیل همه جانبه عوامل و متغیرهای مؤثر بر آنها به‌منظور تصمیم‌گیری صحیح است. اما وجود ابهام و پیچیدگی بین این متغیرها، تصمیم‌گیری در این موارد را بسیار دشوار ساخته است. یافته‌های نظری و عملی حاکی از آن است که استفاده از مدل‌های ترکیبی، به‌ویژه زمانی که مدل‌ها دارای ساختاری کاملاً متفاوت باشند، امری رایج به‌منظور کاهش نرخ طبقه‌بندی نادرست است.

در این مقاله یک مدل پرسپترون چندلایه، که در آن از مزایای خاص محاسبات هوشمند نرم و منطق فازی استفاده شده، به‌عنوان مدلی جایگزین برای طبقه‌بندی صحیح مشتریان

واژه‌نامه

1. linear discriminant analysis
2. quadratic discriminant analysis
3. K-nearest neighbor
4. Support Vector Machines
5. artificial neural networks

مراجع

1. Lee, T. S., Chiu, C. C., Lu, C. J., and Chen, I. F. "Credit Scoring using the Hybrid Neural Discriminant Technique", *Journal of Expert Systems with Applications*, Vol. 23, pp. 245-254, 2002.
2. Gestel, T. V., and Baesens, B., *Credit Risk Management*, Published in the United States by Oxford University Press Inc., New York, 2009.
3. Westgaard, S., and Van der Wijst, N., "Default Probabilities in a Corporate Bank Portfolio: A Logistic Model Approach", *European Journal of Operational Research*, Vol. 135, No. 2, pp. 338-349, 2001.
4. Charitou, A., Neophytou, E., and Charalambous, C., "Predicting Corporate Failure: Empirical Evidence for the UK", *European Accounting Review*, Vol. 13, No. 3, pp. 465-497, 2004.
5. Lee, G., Sung, T. K., and Chang, N., "Dynamics of Modeling in Data Mining: Interpretive Approach to Bankruptcy Prediction", *Journal of Management Information Systems*, Vol. 16, pp. 63-85, 1999.
6. Bellotti, T., and Crook, J., "Support Vector Machines for Credit Scoring and Discovery of Significant

- Features”, *Expert Systems with Applications*, Vol. 36, pp. 3302-3308, 2008.
7. Sharma, S., *Applied Multivariate Techniques*, New York, NY: Wiley, SPSS 1997-Statistic Modeling for Windows 95/98/NT, SPSS Inc, 1998.
 8. Baesens, B., Verstraeten, G., Poel, D. V. d., Egmont-Petersen, M., Kenhove, P. V., and Vanthienen, J., “Bayesian Network Classifiers for Identifying the Slope of the Customer -lifecycle of Long-life Customers”, *European Journal of Operational Research*, Vol. 156, pp. 508-523, 2004.
 9. Sun, L., and Shenoy, P. P., “Using Bayesian Networks for Bankruptcy Prediction: Some Methodological Issues”, *European Journal of Operational Research*, Vol. 180, pp. 738-753, 2007.
 10. Lee, T. S., and Chen, I. F., “A Two-stage Hybrid Credit Scoring Model using Artificial Neural Networks and Multivariate Adaptive Regression Splines”, *Expert Systems with Applications*, Vol. 28, pp. 743-752, 2005.
 11. Kline, D. M., “Two-group Classification using the Bayesian Data Reduction Algorithm”, *Complexity*, Vol. 15, pp. 43-49, 2010.
 12. Huang, C. L., Chen, M. C., and Wang, C. J., “Credit Scoring with a Data Mining Approach Based on Support Vector Machines”, *Expert Systems with Applications*, Vol. 33, pp. 847-856, 2007.
 13. Huang, J. -J., Tzeng, G. -H., and Ong, C. -S., “Two-stage Genetic Programming (2SGP) for the Credit Scoring Model”, *Applied Mathematics and Computation*, Vol. 174, No. 2, pp. 1039-1053, 2006.
 14. Chen, M. C., and Huang, S. H., “Credit Scoring and Rejected Instances Reassigning Through Evolutionary Computation Techniques”, *Expert Systems with Applications*, Vol. 24, pp. 433-441, 2003.
 15. Khashei, M., Bijari, M., and Raissi, Gh. A., “Improvement of Auto-regressive Integrated Moving Average Models using Fuzzy Logic and Artificial Neural Networks (ANNs)”, *Neurocomputing*, Vol. 72, pp. 956-967, 2009.
 16. Celikyilmaz, A., and Turksen, I. B., “Enhanced Fuzzy System Models with Improved Fuzzy Clustering Algorithm”, *IEEE Transactions on Fuzzy Systems*, Vol. 16, pp. 779-794, 2008.
 17. Khashei, M., Bijari, M., and Hejazi, S. R., “Combining Seasonal ARIMA Models with Computational Intelligence Techniques for Time Series Forecasting”, *Soft Computing*, Vol. 16, pp. 1091-1105, 2012.
 18. Lee, T. S., Chiu, C. C., Lu, C. J., and Chen, I. F., “Credit Scoring using the Hybrid Neural Discriminate Technique”, *Expert Systems with Applications*, Vol. 23, pp. 245-254, 2002.
 19. Hsieh, N -Ch., “Hybrid Mining Approach in the Design of Credit Scoring Models”, *Expert Systems with Applications*, Vol. 28, pp. 655-665, 2005.
 20. Hung, C. L., Chen, M. C., and Wang, C. J., “Credit Scoring with a Data Mining Approach Based on Support Vector Machines”, *Expert Systems with Applications*, Vol. 33, pp. 847-856, 2007.
 21. Li, J., Wei, L., Li, G., and Xu, W., “An Evolution Strategy-based Multiple Kernels Multi-criteria Programming Approach: The Case of Credit Decision Making”, *Decision Support Systems*, Vol. 51, pp. 292-298, 2011.
 22. Celikyilmaz, A., and Turksen, I. B., “Uncertainty Modeling of Improved Fuzzy Functions with Evolutionary Systems”, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 38, pp. 1098-1110, 2008.
 23. Chen, F. -L., and Li, F. -Ch., “Combination of Feature Selection Approaches with SVM in Credit Scoring”, *Expert Systems with Applications*, Vol. 37 pp. 4902-4909, 2010.
 24. Bijak, K., and Thomas, L. C., “Does Segmentation Always Improve Model Performance in Credit Scoring”, *Expert Systems with Applications*, Vol. 39, No. 3, pp. 2433-2442, 2012.
 25. Kim, K. S., and Han, I., “The Cluster-indexing Method for Case based Reasoning using Self-organizing Maps and Learning Vector Quantization for Bond Rating Cases”, *Expert Systems with Applications*, Vol. 21, pp. 147-156, 2001.
 26. Park, C., and Han, I., “A Case-based Reasoning with the Feature Weights Derived by Analytic Hierarchy Process for Bankruptcy Prediction”, *Expert Systems with Applications*, Vol. 23, No. 3, pp. 255-264, 2002.
 27. Ahn, H., and Kim, K. -J., “Bankruptcy Prediction Modeling with Hybrid Case-based Reasoning and Genetic Algorithms Approach”, *Applied Soft Computing*, Vol. 9, pp. 599-607, 2009.
 28. Capotorti, A., and Barbanera, E., “Credit Scoring Analysis using a Fuzzy Probabilistic Rough Set Model”, *Computational Statistics and Data Analysis*, Vol. 56, No. 4, pp. 981-994, 2012.
 29. Akkoc, S., “An Empirical Comparison of Conventional Techniques, Neural Networks and the Three Stage Hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) Model for Credit Scoring Analysis: The Case of Turkish Credit Card Data”, *European Journal of Operational Research*, Vol. 222, pp. 168-178, 2012.
 30. Yu, L., Wang, S., and Lai, K., “An Intelligent-agent-based Fuzzy Group Decision Making Model for Financial Multicriteria Decision Support: The Case of Credit Scoring”, *European Journal of Operational Research*, Vol. 195, pp. 942-959, 2009.
 31. Chen, W., Ma, C., and Ma, L., “Mining the Customer Credit using Hybrid Support Vector Machine Technique”, *Expert Systems with Applications*, Vol. 36, pp. 7611-7616, 2009.
 32. Lee, S., and Choi, W. S., “A Multi-industry Bankruptcy Prediction Model using Back-

- propagation Neural Network and Multivariate Discriminant Analysis”, *Expert Systems with Applications*, Vol. 40, pp. 2941-2946, 2013.
33. Zhao, Z., Xu, S., Kong, B. H., Kabir, M. M. J., Liu, Y., and Wasinger, R., “Investigation and Improvement of Multi-layer Perceptron Neural Networks for Credit Scoring”, *Expert Systems with Applications*, Vol. 42, pp. 3508-3516, 2015.
 34. Sohn, S. Y., Kim, H. D., and Yoon, H. J., “Technology Credit Scoring Model with Fuzzy Logistic Regression”, *Applied Soft Computing*, Vol. 43, pp. 150-158, 2016.
 35. Alaraj, M., and Abbod, F., “A New Hybrid Ensemble Credit Scoring Model Based on Classifiers Consensus System Approach”, *Expert Systems With Applications*, Vol. 64, pp. 36-55, 2016.
 36. Neto, R., Adeodato, P. J., and Salgado, C. A., “A Framework for Data Transformation in Credit Behavior Scoring Applications Based on Model Driven Development”, *Expert Systems With Applications*, Vol. 72, pp. 1-13, 2016.
 37. Khashei, M., and Bijari, M., “Hybridization of the Probabilistic Neural Networks with Feed-forward Neural Networks for Forecasting”, *Engineering Applications of Artificial Intelligence*, Vol. 25, pp. 1277-1288, 2012.
 38. Tanaka, H., “Fuzzy Data Analysis by Possibility Linear Models”, *Fuzzy Sets and Systems*, Vol. 24, pp. 363-375, 1987.
 39. Khashei, M., Hejazi, S. R., and Bijari, M., “A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting”, *Fuzzy Set and Systems*, Vol. 159, pp. 769-786, 2008.