



مقایسه عملکرد مدل‌های کلاسیک و هوش مصنوعی در پیش‌بینی وضعیت اعتباری مشتریان بانک

نرجس قاسم نیا عربی^۱، عبدالحمید صفایی قادیکلایی^{۲*}

^۱ کارشناسی ارشد گروه مدیریت صنعتی، دانشکده علوم اقتصادی و اداری، دانشگاه مازندران

^۲ استاد گروه مدیریت صنعتی، دانشکده علوم اقتصادی و اداری، دانشگاه مازندران

تاریخ پذیرش: ۱۳۹۶/۱۲/۲۰

تاریخ دریافت: ۱۳۹۵/۱۰/۱۷

چکیده

در حال حاضر در نظام بانکداری، عدم بازپرداخت تسهیلات به یکی از بزرگ‌ترین مسائل تبدیل شده‌است و به دلیل عدم وجود یک سیستم مناسب برای تخصیص تسهیلات، بانک‌ها و موسسات مالی دچار مشکلات عدیده‌ای از جمله افزایش حجم مطالبات معوق شده‌اند. نظر به اهمیت ریسک اعتباری، بانک‌های تجاری در سطح دنیا در گذشته اغلب از روش قضاوتی برای تعیین ریسک استفاده می‌نمودند، لکن استفاده از این روش‌ها با توجه به توان محدود انسان‌ها در تحلیل هم‌زمان فاکتورهای مختلف مؤثر بر ریسک اعتباری در مقایسه با روش‌های آماری و همچنین روش‌های هوش مصنوعی از کارایی کمتری برخوردار است. به همین منظور این تحقیق درصدد است تا کارایی مدل رگرسیون لجستیک و شبکه عصبی مصنوعی را در تشخیص وضعیت اعتباری مشتریان بانک در فاصله زمانی سال ۱۳۸۸-۱۳۹۲ بسنجد. بررسی نتایج نشان داد که دقت کل مدل شبکه عصبی در داده‌های آموزش ۸۷٪ و رگرسیون لجستیک ۷۷/۲٪ تعیین شده‌است و خطای نوع اول و دوم در شبکه عصبی به میزان قابل‌ملاحظه‌ای نسبت به روش دیگر کاهش یافته است. با توجه به نتایج نمی‌توان انتظار داشت مدل‌های آماری با مفروضات کلاسیک نظیر خطی بودن روابط متغیرها، بتوانند ریسک اعتباری مشتریان را به درستی ارزیابی نماید؛ از این رو بکارگیری یا تلفیق تکنیک‌های هوش مصنوعی در این مساله ضرورتاً توصیه می‌شود.

کلمات کلیدی: اعتبار سنجی، شبکه عصبی مصنوعی، رگرسیون لجستیک، سیستم بانکی

*- نویسنده مسئول: Email: ab.safaei@umz.ac.ir

مقدمه

امروزه بسیاری از بانکها برای افزایش فروش محصولات اعتباری مانند اعطای وام و صدور کارت اعتباری با یکدیگر رقابت می‌کنند و این موضوع حاکی از آن است که آنها باید روند تصمیم‌گیری اعتباری خود را بهبود بخشند (نورلیبایوا و بالاکایوا، ۲۰۱۳). از طرفی به علت رشد سریع صنعت بانکداری، نیاز به مدیریت پرتفوی وام، نیاز به کاهش هزینه‌های ارزیابی اعتباری و لزوم افزایش اثربخشی و کارایی فرایند تصمیم‌گیری، اهمیت بکارگیری سیستم اعتبارسنجی مناسب را در بخش بانکی بسیار بیشتر کرده است (عبدو^۲ و همکاران، ۲۰۱۴).

ارزیابی ریسک اعتباری، یکی از مسائل مهم و پرچالش در زمینه تحلیل‌های مالی به شمار می‌آید زیرا از این طریق می‌توان از خسارت‌های کلان که پیامد تصمیمات نادرست واگذاری اعتبار (وام) به متقاضیان است تا اندازه زیادی اجتناب کرد (یو^۳ و همکاران، ۲۰۰۸).

طراحی روش علمی و مناسب برای جلوگیری از اعمال سلیقه‌های مختلف فردی در رتبه‌بندی مشتریان می‌تواند گامی مؤثر در جهت افزایش کارایی نظام بانکی باشد. توجه به یکی از مهم‌ترین دغدغه‌های سیستم بانکی که همانا تخصیص بهینه وجوه جمع‌آوری شده و کاهش مطالبات معوق است با برخورداری از سیستم مناسب رتبه‌بندی مشتریان، امکان‌پذیر خواهد بود (فوگارتی^۴، ۲۰۱۲).

با توجه به اهمیت و ضرورت فرایند اعتبارسنجی در روند اعطای وام به مشتریان بانک، هدف تحقیق حاضر تعیین مدل مناسب جهت اعتبارسنجی متقاضیان وام جهت کاهش ریسک مطالبات معوق می‌باشد. با توجه به هدف مذکور سوالات تحقیق را می‌توان به شرح زیر فهرست نمود: ۱- متغیرهای مؤثر در اعتبارسنجی مشتریان بانک مورد مطالعه کدامند؟ ۲- دقت عملکرد مدل رگرسیون لجستیک در سنجش اعتبار مشتریان بانک به چه میزان است؟ ۳- دقت عملکرد سیستم شبکه عصبی مصنوعی در سنجش اعتبار مشتریان بانک به چه میزان است؟ ۴- مدل مناسب از نظر دقت، خطای نوع اول و دوم جهت اعتبارسنجی مشتریان وام کدام است؟

1- Nurlybayeva & Balakayeva

2- Abdou

3- Yu

4- Fogarty

در این راستا، ابتدا مفاهیم اساسی اعتبارسنجی مورد بررسی قرار می‌گیرد، پس از ارائه مبانی اصلی شبکه عصبی مصنوعی و رگرسیون لجستیک، طراحی مدل و تحلیل داده‌ها انجام می‌گیرد و در نهایت عملکرد مدل شبکه عصبی مصنوعی و رگرسیون لجستیک مورد مقایسه قرار می‌گیرد. هرکدام از مدل‌ها که دقت بالاتری داشته باشد و خطای نوع دوم آن کمتر باشد به‌عنوان مدل کارآ انتخاب خواهد شد.

مبانی نظری و پیشینه پژوهش

در طول دهه‌های اخیر ریسک‌های مالی در محیط، زیان‌های جبران‌ناپذیری برای مؤسسات مالی به همراه داشته است. از این‌رو پیش‌بینی ریسک‌های مالی امر بسیار مهمی برای مؤسسات مالی به شمار می‌آید (لی و ژونگ^۱، ۲۰۱۲). مهم‌ترین ریسک برای بانک‌ها و مؤسسات مالی، مسئله تشخیص نادرست نسبت به شایستگی متقاضیان دریافت اعتبار است، در حالی که احتمال قصور در بازپرداختشان وجود دارد.

با مطالعه ادبیات حول موضوع اعتبارسنجی تعاریف گوناگونی از سوی پژوهشگران ارائه شده است و یک تعریف جهانی پذیرفته از اعتبارسنجی وجود ندارد. با این حال در بسیاری از تعاریف، اعتبارسنجی را به‌عنوان یک ابزار بسیار ضروری تعریف می‌کنند که با استفاده از روش‌های پارامتریک و ناپارامتریک در مورد وضعیت اعتباری مشتریان و خوش‌حساب و بدحساب بودن آنها قضاوت می‌کنند.

تصمیم‌گیری در مورد اعطای اعتبار به یک متقاضی، به‌طور سنتی بر پایه قضاوت‌های ذهنی، استفاده از تجارب گذشته و برخی از اصول راهنما است. یکی از این روش‌ها، روش معمول 3C، 4C یا 5C اعتبار است که عبارت هستند از: شخصیت^۲، ظرفیت^۳، سرمایه^۴، وثیقه^۵، وضعیت^۶. این روش‌ها معمولاً با هزینه‌های بالای آموزش، تصمیمات نادرست مکرر، تصمیمات متناقض متخصصان مختلف در یک زمینه مشابه همراه است. این کاستی‌ها تمایل به استفاده از روش‌های رسمی و دقیق برای ارزیابی ریسک اعتباری را افزایش داده است. در این زمینه روش‌های امتیازدهی هوشمند

-
- 1- Li & Zhong
 - 2- Character
 - 3- Capacity
 - 4- Capital
 - 5- Collateral
 - 6- Condition

به عنوان ابزارهای اولیه است که مؤسسات مالی برای ارزیابی ریسک اعتباری، بهبود جریان نقدی، کاهش ریسک‌های ممکن و تصمیم‌گیری‌های مدیریتی از آن بهره می‌برند (مارکوئیس^۱ و همکاران، ۲۰۱۲).

اغلب بانک‌ها و مؤسسات مالی و اعتباری که به‌نوعی درگیر اعطای وام هستند، معمولاً یکی از روش‌های موجود اعتبارسنجی را براساس شرایط خود و جامعه پیرامون بکار می‌گیرند. روش‌های امتیازدهی اعتباری به دو صورت کمی و کیفی انجام می‌شوند. تحلیل کیفی امتیازدهی اعتباری بستگی به توانایی و تجربه افراد مسئول اعطای اعتبار دارد (دیمیتریو^۲ و همکاران، ۲۰۱۰). امروزه در اغلب بانک‌های تجاری دنیا از روش قضاوتی (کیفی) برای تعیین ریسک استفاده می‌شود، لکن استفاده از این روش با توجه به توان محدود انسان‌ها در تحلیل هم‌زمان فاکتورهای مختلف مؤثر بر ریسک در مقایسه با روش‌های آماری و همچنین روش‌های هوش مصنوعی از کارایی کمتری برخوردار است. در واقع رویکرد قضاوتی به شدت به تجارب گذشته و حال تحلیل‌گران اعتباری بستگی دارد و معیارهای ذهنی، تناقض‌ها و اولویت‌های فردی نتایج تصمیمات را تحت تاثیر قرار می‌دهند (لی و ژونگ، ۲۰۱۲). ولی در روش‌های کمی امتیازدهی، پیش‌بینی عدم بازپرداخت اصل و سود تسهیلات اعتباری بستگی به تابع توزیع برآورد شده به وسیله این روش‌ها، دارد (دیمیتریو و همکاران، ۲۰۱۰).

از کاربردی‌ترین رویکردهای کمی در امتیازدهی اعتباری به‌کارگیری روش‌های آماری نظیر تحلیل تمایزی، رگرسیون لجستیک و خطی، تکنیک MARS^۳، درخت رگرسیون و طبقه‌بندی، هموارسازی ناپارامتریک^۴، تحلیل بقا^۵ و مدل‌های تحقیق در عملیات نظیر برنامه‌ریزی خطی، برنامه‌ریزی درجه دوم، برنامه‌ریزی عدد صحیح، برنامه‌ریزی چند معیاره، برنامه‌ریزی پویا است، اما اخیراً می‌توان روش‌های پیچیده‌تری مربوط به حوزه هوش محاسباتی یافت که اغلب به محاسبات نرم یا داده‌کاوی، نظیر شبکه‌های عصبی مصنوعی، ماشین بردار پشتیبانی، سیستم ایمنی مصنوعی، الگوریتم ژنتیک و دیگر الگوریتم‌های تکاملی اشاره دارد. اهمیت

-
- 1- Marques
 - 2- Dimitriu
 - 3- Multivariate Adaptive Regression Splines
 - 4- Nonparametric Smoothing
 - 5- Survival Analysis

تصمیم‌گیری در زمینه اعطای اعتبار برای مؤسسات مالی باعث افزایش تمایل به استفاده از انواع تکنیک‌های هوش محاسباتی شده است (مارکوئیس و همکاران، ۲۰۱۲).

در ادبیات موضوعی تحقیق تکنیک‌های گوناگونی برای ارزیابی ریسک اعتباری در بانک بر اساس متغیرهای مرتبط با موضوع مورد بررسی بکار گرفته شده است. جدول ۱ شرح مختصری از این تحقیقات را نمایش می‌دهد.

جدول ۱- برخی پژوهش‌های انجام شده در زمینه اعتبارسنجی

| محقق/سال | سال | عنوان | شرح مختصر |
|---------------------|------|---|--|
| تقوی فرد و نادعلی | ۱۳۹۱ | طبقه بندی متقاضیان تسهیلات اعتباری بانکی با استفاده از ابزارهای داده کاوی و منطق فازی | این تحقیق به مقایسه روش‌های درخت تصمیم، شبکه عصبی، شبکه بی‌زین، ماشین بردار پشتیبانی، الگوریتم ژنتیک و رگرسیون لجستیک برای طبقه‌بندی متقاضیان وام پرداخته است. نتایج نشان داد که تکنیک درخت تصمیم فازی از لحاظ دقت تفکیک مشتریان نسبت به درخت‌های سنتی و روش‌های آماری رگرسیون لجستیک، شبکه‌های بی‌زین و شبکه‌های عصبی نتایج بهتری داشته است؛ ولی نسبت به مدل‌های درخت ژنتیکی و ماشین بردار پشتیبان دقت کمتری داشته است. |
| دهمرد و همکاران | ۱۳۹۱ | اعتبارسنجی مشتریان بانک با استفاده از رویکرد امتیازدهی اعتباری | در این تحقیق از مدل آماری رگرسیون لجستیک برای اعتبارسنجی مشتریان بانک استفاده شده است. نتایج حاصل از این پژوهش نشان داد که بر اساس شاخص‌های آماری، رگرسیون لجستیک از نظر ضرایب و همچنین قدرت تفکیک کنندگی معنادار بوده و در مدیریت ریسک اعتباری بانک از اعتبار بالایی برخوردار است. |
| میر طلایی و همکاران | ۱۳۹۱ | ارائه الگوریتم هوشمند مبتنی بر اعتماد جهت تعیین اعتبار مشتریان یک سیستم مالی | در این تحقیق از شبکه عصبی مصنوعی برای ارائه مدل اعتبارسنجی مشتریان بانک بر اساس سطح اعتماد استفاده شده است. بر اساس نتایج تحقیق مدل پیشنهادی قادر است مشتریان را در ۶ سطح تعریف شده برای اعتماد گروه‌بندی نماید. |
| کوزنی ^۱ | ۲۰۱۵ | الگوریتم‌های ژنتیک برای اعتبارسنجی: مقایسه عملکرد تابع ارزیابی جایگزین | وی در این تحقیق به بررسی و مقایسه عملکرد توابع ارزیابی گوناگون در الگوریتم ژنتیک برای پیش‌بینی رفتار اعتباری مشتریان بانک پرداخت. نتایج حاکی از آن است که تابع ارزیابی بیت‌ماسک ^۲ در معیارهای دقت و حساسیت نسبت به معادله چند جمله‌ای ^۳ و برآورد دامنه پارامتر ^۴ عملکرد بهتری داشته است. |
| عبود و همکاران | ۲۰۱۴ | آیا اعتبارسنجی در مؤسسات مالی اسلامی قابل بکارگیری می‌باشد | آنها در این پژوهش به مقایسه سه تکنیک تحلیل تمایزی ^۵ (DA)، رگرسیون لجستیک ^۶ (LR)، شبکه عصبی پرسپترون چند لایه ^۷ (MPNN) جهت ارائه یک مدل اعتبارسنجی پرداختند. نتایج نشان داد که مدل شبکه عصبی پرسپترون چند لایه بهتر از بقیه تکنیک‌ها عمل کرده است و بالاترین نرخ دقت طبقه‌بندی را داشته است. |

- 1- Kozney
- 2- Bitmask
- 3- Polynomial equation
- 4- Parameter range estimation
- 5- Discriminant Analysis
- 6- Logistic Regression
- 7- Multi-layer Perceptron Neural Network

| | | | |
|--|------|------------------------------|---|
| طراحی مدلی جهت ارزیابی ریسک اعتباری مشتریان بانک اردن با رویکرد شبکه عصبی مصنوعی | ۲۰۱۴ | بخت و الت ^۱ | آنها به مقایسه دو مدل شبکه عصبی مصنوعی و رگرسیون لجستیک برای ارائه مدلی جهت اعتبارسنجی پرداختند. نتایج حاکی از آن بود که شبکه عصبی در شناسایی و پیش بینی مشتریان بدحساب، تشخیص پتانسیل بد حسابی مشتریان و حداقل کردن خطای نوع دوم بهتر از روش دیگر عمل کرده است. |
| تاثیر امتیاز دهی اعتباری بر وام ها | ۲۰۱۳ | ایناو ^۲ و همکاران | آنها به بررسی تاثیر متغیرهای اعتبارسنجی بر امتیاز اعتباری متقاضیان با استفاده از روش آماری رگرسیون پرداختند. نتایج نشان داد که اعطای وام به مشتریان با ریسک بالا با توجه به شرایط سخت و دقیق پیش پرداخت صورت می گیرد و وام دهی به مشتریان با ریسک پایین از طریق تأمین مالی با کیفیت بالا و خودرو های گران قیمت گسترش می یابد. |
| مدلها و تحقیقات تجربی در زمینه امتیازدهی با ابزار های متغیر داده کاوی | ۲۰۱۳ | هویی ^۳ و همکاران | در این تحقیق به مقایسه دو مدل رگرسیون لجستیک و برنامه ریزی خطی چند معیاره ^۴ پرداخته شد. نتایج نشان دادند که برنامه ریزی خطی چند معیاره از قدرت پیش بینی بهتری برخوردار بوده است. |
| مدل های ترکیبی امتیازدهی اعتباری با استفاده از هوش مصنوعی و رگرسیون لجستیک | ۲۰۱۳ | لو و همکاران | آنها با استفاده از هوش مصنوعی و رگرسیون لجستیک به طراحی مدل مناسب جهت ارزیابی ریسک اعتباری پرداختند. نتایج تحقیق نشان داد که تکنیک هوش مصنوعی در ترکیب با روش های نظیر رگرسیون لجستیک نتایج بهتری خواهد داد. |
| بررسی مدل های امتیاز دهی اعتباری | ۲۰۱۳ | نورلیبایوا و بالاکایوا | آنها به بررسی مدل های اعتبارسنجی مبتنی بر شبکه عصبی مصنوعی و ماشین بردار پشتیبانی با توجه به حجم متفاوتی از نمونه پرداختند. نتایج نشان داد کارایی مدل های اعتبار سنجی در بیشتر مواقع به حجم داده های نمونه بستگی دارد. |
| مدل رگرسیون لاجیت با ضرایب تصادفی را برای ساخت مدل امتیازدهی اعتباری | ۲۰۱۲ | دانگ ^۵ و همکاران | آنها به منظور بهبود عملکرد مدل رگرسیون لجستیک، این مدل را با ضرایب تصادفی ارائه نمودند. نتایج نشان داد که دقت پیش بینی مدل رگرسیون ارائه شده به دلیل ویژگی خاص آن در این پژوهش نسبت به مدل رگرسیون سایر تحقیقات بیشتر است. |

با مطالعه تحقیقات انجام شده در موضوع اعتبارسنجی مشتریان بانک، تاکنون متغیرهای متعددی برای ارزیابی وضعیت اعتباری متقاضیان وام ارائه شده است که بعضی از پرتکرارترین آنها جمع آوری و با نظر خبرگان شرکت نهایی شد که در جدول ۲ نشان داده شده است.

- 1- Bekhet & Eletter
- 2- Einav
- 3- Hui
- 4- Multiple Criteria Linear Programming
- 5- Dong

جدول ۲- متغیرهای اعتبارسنجی

| متغیر | منابع |
|---------------|--|
| جنسیت | هریس (۲۰۱۵)، ژاوو و همکاران (۲۰۱۵)، عبود و پوینتن (۲۰۱۴)، عبود (۲۰۰۹)، سوسترسیک و همکاران (۲۰۰۹)، عبود و پوینتن (۲۰۰۹)، سارلیجا و دیگران (۲۰۰۶)، لی و چن (۲۰۰۵)، لیو (۲۰۰۱)، دوراند (۱۹۴۱)، جلیلی و دیگران (۱۳۸۹) |
| تحصیلات | کوزنی (۲۰۱۵)، ژاوو و همکاران (۲۰۱۵)، عبود و پوینتن (۲۰۱۴)، عبود (۲۰۰۹)، عبود و پوینتن (۲۰۰۹)، لی و چن (۲۰۰۵)، لیو (۲۰۰۱)، جلیلی و دیگران (۱۳۸۹)، رجب زاده و دیگران (۱۳۸۸) |
| وضعیت سکونت | کوزنی (۲۰۱۵)، هریس (۲۰۱۵)، ژاوو و همکاران (۲۰۱۵)، نگوین (۲۰۱۴)، عبود و پوینتن (۲۰۱۴)، عبود (۲۰۰۹)، عبود و پوینتن (۲۰۰۹)، لیو (۲۰۰۱)، گرین (۱۹۹۸) |
| شغل | کوزنی (۲۰۱۵)، هریس (۲۰۱۵)، ژاوو و همکاران (۲۰۱۵)، نگوین (۲۰۱۴)، عبود و پوینتن (۲۰۱۴)، عبود و پوینتن (۲۰۰۹)، سارلیجا و دیگران (۲۰۰۶)، لی و چن (۲۰۰۵)، لیو (۲۰۰۱)، وست (۲۰۰۰)، گرین (۱۹۹۸)، دوراند (۱۹۴۱)، میرطلایی و دیگران (۱۳۹۱)، جلیلی و دیگران (۱۳۸۹) |
| وضعیت چک | میرطلایی و دیگران (۱۳۹۱)، رجب زاده و دیگران (۱۳۸۸)، اکرامی و رهنما (۱۳۸۸) |
| سابقه اعتباری | کوزنی (۲۰۱۵)، هریس (۲۰۱۵)، ژاوو و همکاران (۲۰۱۵)، نگوین (۲۰۱۴)، میرطلایی و دیگران (۱۳۹۱)، رجب زاده و دیگران (۱۳۸۸)، اکرامی و رهنما (۱۳۸۸) |
| نوع وثیقه | ژاو و همکاران (۲۰۱۵)، عبود و پوینتن (۲۰۱۴)، عبود و پوینتن (۲۰۰۹)، جلیلی و دیگران (۱۳۸۹)، البرزی و دیگران (۱۳۸۹)، اکرامی و رهنما (۱۳۸۸) |
| نرخ سود | ژاوو و همکاران (۲۰۱۵)، عبود و پوینتن (۲۰۰۹)، لیو (۲۰۰۱)، وست (۲۰۰۰)، میرطلایی و دیگران (۱۳۹۱)، اکرامی و رهنما (۱۳۸۸) |

روش‌شناسی تحقیق

در این پژوهش به منظور ارزیابی اعتباری مشتریان بانک و ارائه مدل شبکه عصبی، متغیرهای تأثیرگذار بر ریسک اعتباری مشتریان با مطالعه ادبیات پژوهش، شناسایی شدند. ابتدا به منظور انتخاب متغیرهای مهم و تأثیرگذار پرسشنامه‌ای براساس روش دلفی - ساعتی، بین خبرگان دانشگاهی و مدیران بانک توزیع شد و تمامی متغیرهایی که میانگین درجه اهمیت آنها بالاتر از هفت بود، انتخاب شدند که مطابق جدول (۲) شامل ۸ متغیر می‌باشند. این متغیرها به‌عنوان ورودی شبکه عصبی و همچنین متغیر مستقل در رگرسیون لجستیک به منظور طراحی مدل اعتبارسنجی در نظر گرفته شد. بدین منظور اطلاعات مربوط به تمام مشتریان حقیقی که در بازه ۵ ساله ۸۸ تا ۹۱ از بانک سینا وام دریافت نموده‌اند از مدیریت شعب مختلف بانک دریافت گردید اما به دلیل کامل نبودن اطلاعات اعتباری برخی از مشتریان در نهایت اطلاعات مربوط به ۳۳۴ مشتری جهت ساخت مدل مورد استفاده قرار گرفت. در میان ۳۳۴

مشتری، ۹۶ نفر مشتری بدحساب و ۲۳۸ نفر مشتری خوش حساب می باشند. پس از تعیین متغیرهای کلیدی، در ابتدا مجموعه داده‌ها به دو گروه آموزش و آزمایش (آزمون) تقسیم گردید. بر اساس مطالعات صورت گرفته بطور متعارف ۲۰ درصد از مجموعه کل داده‌ها جهت آزمودن نهایی کارآمدی مدل کنار گذاشته می شود و از ۸۰ درصد مابقی داده‌ها جهت آموزش شبکه عصبی و دستیابی به مدل مناسب طبقه بندی اعتباری مشتریان استفاده شده است. به این ترتیب با استفاده از روش‌های رگرسیون لجستیک و شبکه عصبی مدل طبقه بندی مشتریان استخراج گردید، به نحوی که بتوان اعتبار مشتریان را از طریق هر یک از این دو مدل پیش بینی کرد. کارآمدی هر یک از این مدل‌ها در پیش بینی اعتبار مشتریان از طریق محاسبه میزان خطای پیش بینی هر یک از آن‌ها در پیش بینی وضعیت اعتباری مشتریان در داده‌های آزمایش محاسبه می گردد.

رگرسیون لجستیک

رگرسیون لجستیک شکل خاصی از رگرسیون خطی است که در آن متغیر وابسته به شکل صفر یا یک تعریف می شود. در این روش محدودیت‌های کمتری در فرضیه‌ها وجود دارد و می تواند با شاخص‌های کیفی نیز کار کند. قابلیت تحلیل تمایزی خطی (LDA) نسبت به رگرسیون لجستیک در آن است که می تواند نشان دهد آیا متغیرهای مربوط به ویژگی مشتری با هم مرتبط هستند یا خیر، در حالی که رگرسیون لجستیک این قابلیت را دارد که احتمال نکول از سوی متقاضی را پیش بینی کند و متغیرهای مرتبط با رفتار مشتری را شناسایی می کند. معادله رگرسیون لجستیک به این ترتیب می باشد:

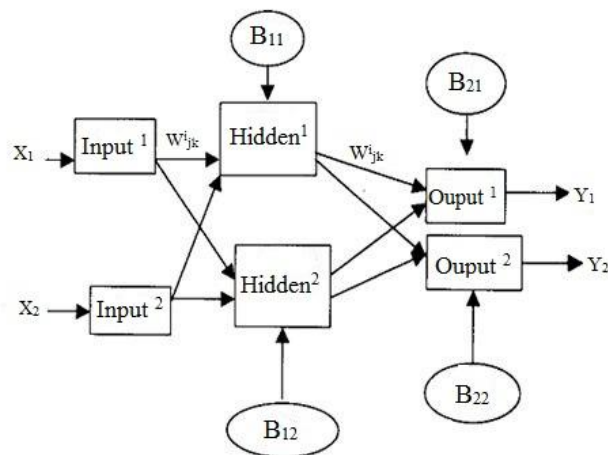
$$\ln \left[\frac{p_i}{1 - p_i} \right] = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad \text{رابطه (۱)}$$

احتمال p_i که از معادله بالا به دست می آید حد طبقه بندی است. زمانی که p_i احتمال عدم وقوع نکول را نشان می دهد، هرچه این احتمال بزرگتر از ۰/۵ باشد و نزدیک به ۱ باشد، مشتری خوش حساب یا مشتری که احتمال نکول ندارد. اگر کمتر از ۰/۵ باشد مشتری بدحساب تلقی می گردد (لی و ژونگ، ۲۰۱۲).

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی یک مدل پردازش اطلاعات است که شبیه ساختارهای ارتباطی سیناپس می‌باشد. این شبکه شامل تعداد زیادی گره (که واحد یا نورون نامیده می‌شود) است که به یکدیگر متصل شده‌اند. شبکه‌های عصبی مصنوعی روبه‌جلو و پس‌انتشار در سطح وسیعی در اعتبار سنجی به کار گرفته شده‌اند (لی و ژونگ، ۲۰۱۲). یکی از کاربردهای شبکه عصبی، پیش‌بینی و تخمین یک متغیر ویژه با استناد به تعداد ورودی است. مدل‌های شبکه عصبی رابطه میان داده‌های ورودی و خروجی را مشابه مدل‌های رگرسیون غیرخطی تخمین می‌زنند. در این مدل، کل داده‌ها به دو گروه آموزش و آزمایش تقسیم می‌شود که با کمک داده‌های آموزش مدل‌های مختلف شبکه عصبی مصنوعی با هدف حداقل‌سازی خطای طبقه بندی، مورد برآزش قرار می‌گیرد. سپس عملکرد مدل در شرایط محیط واقعی با استفاده از داده‌های آزمایش مورد آزمون قرار خواهد گرفت (آنجلینی^۱، ۲۰۰۸).

شکل ۱ یکی از مدل‌های معروف شبکه عصبی را که پرسپترون چندلایه نامیده می‌شود، نشان می‌دهد:



شکل ۱- شبکه عصبی پرسپترون چندلایه با ۲ ورودی و ۲ خروجی

1 - Angelini

همان طور که ملاحظه می شود این شبکه دارای یک لایه ورودی، یک لایه خروجی و یک لایه پنهان می باشد. در این مدل x_1, x_2 بردار ورودی و y_1 و y_2 بردار خروجی و w_{jk}^i وزن متغیر k ام در لایه i ام را نشان می دهد.

به جز لایه ورودی، هر کدام از نورون های لایه پنهان در مدل فوق تابع تبدیل مربوط به لایه مربوط را نشان می دهد؛ بنابراین خروجی یکی از نورون های لایه پنهان به عنوان مثال به صورت زیر خواهد بود:

$$Y^H = g\left(\sum_{i=1}^2 w_{jk}^i x_j\right) + w_{jb} \quad \text{رابطه ۳}$$

با داشتن مقدار تابع لایه پنهان، مقدار لایه خروجی به صورت زیر تعریف خواهد شد:

$$Y^O = \sum_{b=1}^2 w^2_{kj} (g\left(\sum w_{jk}^i x_j\right) + w_{jb}^2) + w_{jb}^2, k \quad \text{رابطه ۴}$$

با توجه به اینکه در طبقه بندی شبکه های عصبی، داده ها به دو گروه شبکه های بدون ناظر و با ناظر تقسیم می شوند، زمانی که متغیر ورودی و هم متغیر خروجی برای مدل مشخص باشد، مدل مربوط به سهولت می تواند مقادیر خطا را تعیین و به تبع آن بردار وزن های مدل را بهبود بخشد؛ بنابراین حلقه یادگیری تا دستیابی به بردار وزن مطلوب ادامه خواهد یافت.

یافته های پژوهش

برای طراحی مدل های شبکه عصبی و برآورد پارامترهای مدل از نرم افزار متلب^۱ و برای برآورد پارامترهای مدل کلاسیک از نرم افزار اسپس^۲ استفاده شده است. ساختار مدل رگرسیون لجستیک و شبکه های عصبی برای هر گروه با استفاده از داده های آموزشی برآورد شد و با استفاده از داده های آزمایش مورد آزمون قرار گرفت.

متغیرهای تاثیرگذار بر وضعیت اعتباری مشتریان بانک

با استفاده از نظر خبرگان دانشگاهی و مدیران و سرپرستان بانک مورد مطالعه، متغیرهای مؤثر بر ارزیابی وضعیت اعتباری تعیین شدند و نتایج این ارزیابی در جدول (۳) ارائه شده است.

1- MATLAB
2- SPSS

جدول ۳- متغیرهای نهایی پژوهش

| متغیر | عنوان | نوع متغیر | توضیحات |
|----------------|---------------|-----------|--|
| X ₁ | جنسیت | اسمی | X ₁₋₁ (مرد)، X ₁₋₂ (زن) |
| X ₂ | تحصیلات | ترتیبی | X ₂₋₁ (بی‌سواد)، X ₂₋₂ (زیر دیپلم)، X ₂₋₃ (دیپلم)، X ₂₋₄ (لیسانس)، X ₂₋₅ (فوق لیسانس) |
| X ₃ | سکونت | اسمی | X ₃₋₁ (شخصی)، X ₃₋₂ (استیجاری)، X ₃₋₃ (منزل والدین)، X ₃₋₄ (سازمانی) |
| X ₄ | شغل | اسمی | X ₄₋₁ (کارمند دولتی)، X ₄₋₂ (کارمند خصوصی)، X ₄₋₃ (آزاد) |
| X ₅ | سابقه اعتباری | ترتیبی | X ₅₋₁ (تسویه شده)، X ₅₋₂ (فعال)، X ₅₋₃ (ندارد)، X ₅₋₄ (سررسید گذشته)، X ₅₋₅ (معوق)، X ₅₋₆ (مشکوک الوصول) |
| X ₆ | وضعیت چک | ترتیبی | X ₆₋₁ (چک برگشتی ندارد)، X ₆₋₂ (رفع سوء اثر شده)، X ₆₋₃ (دسته چک ندارد)، X ₆₋₄ (عدم رفع سوء اثر) |
| X ₇ | نرخ سود | نسبی | |
| X ₈ | نوع وثیقه | اسمی | X ₈₋₁ (سند ملکی)، X ₈₋₂ (سفته)، X ₈₋₃ (سپرده)، X ₈₋₄ (چک تضمینی)، X ₈₋₅ (سهام)، X ₈₋₆ (چک عادی) |

مدل رگرسیون لجستیک

مدل رگرسیون لجستیک برای برآورد ریسک اعتباری مشتریان به صورت زیر می‌باشد. همانطور که در بالا بیان شد احتمال عدم وقوع نکول را نشان می‌دهد.

رابطه ۵)

$$\ln\left(\frac{p}{1-p}\right) = 3.906 - 0.59x_{1-1} + 0.574x_2 - 0.969x_{3-2} + 0.698x_{4-1} - 0.683x_5 - 0.627x_6 - 0.1x_7 + 2.145x_{8-4}$$

در رگرسیون لجستیک متغیرهایی که در سطح معنی‌داری ۱۰ درصد هستند در مدل باقی می‌مانند و بقیه حذف می‌شوند زیرا رابطه معنی‌داری با مدل برآورد شده ندارند. ضرایب منفی در مدل لجستیک بیانگر رابطه منفی آن‌ها با خوش‌حسابی و ضرایب مثبت رابطه مثبت متغیرهای مستقل را بر متغیر وابسته خوش‌حسابی نشان می‌دهند. متغیر وابسته مدل ارائه شده، وضعیت اعتباری مشتری است که در دو گروه «خوش‌حساب» و «بدحساب» قرار می‌گیرد. در صورتیکه خروجی مدل رگرسیون ارائه شده مقدار مثبت باشد بدین معنی است که احتمال عدم نکول (P) بیشتر از احتمال نکول (1-p) است بنابراین مشتری در گروه خوش حساب قرار می‌گیرد و اگر خروجی مدل مقدار منفی باشد بدین معنی است که احتمال نکول (1-p) بیشتر از احتمال عدم نکول (P) است بنابراین مشتری در گروه بد حساب قرار خواهد گرفت.

در جدول ۴ نیز نتایج طبقه‌بندی مدل رگرسیون لجستیک ارائه شده است، درصد پیش‌بینی درست داده‌های آموزش و آزمایش به‌طور مجزا در ستون آخر آورده شده است. داده‌های آموزش شامل ۲۶۶ مشتری می‌باشد که از این میان، ۱۹۶ مشتری خوش‌حساب و ۷۰ مشتری بدحساب بوده است. مدل رگرسیون لجستیک در پیش‌بینی مشتریان بدحساب ۵۱/۴ درصد و در پیش‌بینی مشتریان خوش‌حساب ۸۸/۷ درصد

درست عمل کرده است و دقت کل مدل رگرسیون در طبقه‌بندی مشتریان خوش حساب و بدحساب ۷۸/۷ درصد بوده است. مدل رگرسیون که با ۸۰ درصد داده‌ها آموزش دیده است، توسط داده‌های جدیدی (۲۰ درصد مابقی داده‌ها) مورد آزمایش قرار می‌گیرد. در مجموعه آزمایش ۶۸ مشتری وجود دارد که ۴۲ نفر خوش حساب و ۲۶ نفر بدحساب می‌باشند. مدل پیشنهادی در برآورد داده‌های آزمایش دقت ۵۴/۴ درصدی داشته است به گونه‌ای که در پیش‌بینی مشتریان خوش حساب ۶۱/۹ درصد و مشتریان بدحساب ۴۲/۳ درصد درست پیش‌بینی کرده است.

جدول ۴- نتایج طبقه‌بندی مدل رگرسیون لجستیک

| داده‌ها | واقعی | پیش‌بینی | | |
|-----------------|----------|----------|----------|-------|
| | | بدحساب | خوش حساب | % صحت |
| داده‌های آموزش | بدحساب | ۳۶ | ۳۴ | ۵۱/۴ |
| | خوش حساب | ۲۲ | ۱۷۴ | ۸۸/۷ |
| | % کل | ۲۱/۸ | ۷۸/۲ | ۷۸/۷ |
| داده‌های آزمایش | بدحساب | ۱۱ | ۱۵ | ۴۲/۳ |
| | خوش حساب | ۱۶ | ۲۶ | ۶۱/۹ |
| | % کل | ۳۹/۷ | ۶۰/۳ | ۵۴/۴ |

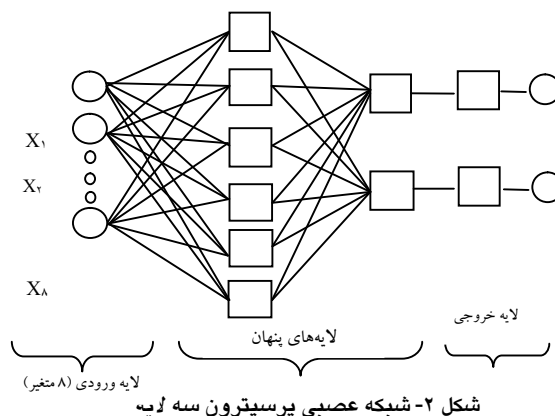
(منبع: یافته‌های حاصل از پژوهش)

مدل شبکه عصبی

در این مرحله برای ساخت مدل شبکه عصبی مصنوعی به جعبه ابزار پیش‌ساخته در نرم افزار متلب اکتفا نشده و از کد نویسی در محیط اسکریپت^۱ متلب استفاده شده است تا در کمترین زمان حالت‌های مختلف شبکه عصبی در نوروها و لایه‌های متفاوت مورد آزمون قرار گیرد. نتایج مدل برازش شده در این تحقیق شبکه عصبی مصنوعی پرسپترون سه لایه (دو لایه پنهان) روبه‌جلو با الگوریتم آموزش پس انتشار خطا می‌باشد که در شکل ۲ نشان داده شده است. این شبکه یکی از پر کاربردترین مدل‌های شبکه‌های عصبی در مسائل پیش‌بینی و مدل‌سازی به ویژه در حوزه اعتبارسنجی می‌باشد. توانایی این شبکه در پیش‌بینی ریسک اعتباری باعث شده که به عنوان متداول‌ترین ساختار شبکه عصبی در حوزه طبقه‌بندی مطرح شود (براون و میوس^۲، ۲۰۱۲؛ لی و ژونگ، ۲۰۱۲).

1- Script

2- Brown & Mues



داده‌های ورودی: اطلاعات مربوط به ۸ متغیر وضعیت اعتباری مشتری در چهار دوره (سال ۸۸ تا ۹۱) به عنوان ورودی مدل شبکه در نظر گرفته شده است. داده‌های خروجی: با توجه به اطلاعاتی که در مورد مشتریان از بانک بدست آمد، وضعیت اعتباری مشتریان در دو وضعیت "خوش حساب" و "بد حساب" کد گذاری شده است. نظر به اینکه دو طبقه خوش حساب و بد حساب به عنوان طبقات هدف مورد نظر شبکه بوده است، تعداد نورون‌های خروجی شبکه نیز دو گره در نظر گرفته شده است.

تابع تبدیل: در تمامی تحقیقاتی که در زمینه اعتبارسنجی در این تحقیق بررسی شده است، از تابع تبدیل زیگموئید^۱ برای نورون‌های لایه پنهان و تابع تبدیل پیورلین^۲ برای نورون لایه خروجی استفاده شده است. دلیل اصلی استفاده گسترده از این تابع، عملکرد بهتر شبکه‌های ایجاد شده با توابع عنوان شده است. لذا در این تحقیق نیز این توابع به عنوان تابع تبدیل نورون بکار گرفته شده است.

تعداد نورون‌های لایه پنهان: برای تعیین تعداد نورون‌های لایه پنهان از روش سعی و خطا استفاده شده است. در این مرحله، حالت‌های مختلف شبکه عصبی با تعداد نورون و لایه‌های متفاوت اجرا و در هر حالت نیز ۱۰۰۰ مرتبه سعی^۳ شده است و در نهایت عملکرد حالت‌ها با یکدیگر مورد مقایسه قرار گرفت. برای ارزیابی و مقایسه عملکرد مدل‌های پیش‌بینی و طبقه‌بندی از معیارهایی نظیر میانگین مجذور خطا^۴ (MSE)، ریشه میانگین مجذور خطا^۱ (RMSE)، معیار عدم تطابق^۲ و ... استفاده

- 1- Sigmoid
- 2- Purelin
- 3- trying
- 4- Mean Square Error

می‌شود (عبدو و پوینتین، ۲۰۱۱). در این تحقیق نیز از معیار عدم تطابق برای مقایسه عملکرد مدل شبکه عصبی با تعداد نورون‌های متفاوت در لایه پنهان استفاده شده است که در جدول ۵ نشان داده شده است.

معیار توقف: در ابتدا ساختار احتمالی برای شبکه ارائه می‌شود. سپس مدل‌های مختلف با استفاده از داده‌های تقریب مدل اجرا شده و در نهایت کارایی آن‌ها با سطح عدم تطابق مورد ارزیابی قرار می‌گیرد. در این فرایند، آموزش هنگامی متوقف می‌شود که هیچ بهبودی در مقدار عدم تطابق رخ ندهد. مطابق جدول ۵ شبکه عصبی سه لایه با دو لایه پنهان با سطح عدم تطابق ۰/۱۲۶۹ به عنوان بهترین مدل طبقه بندی انتخاب شده است. در جدول ۶ نتایج طبقه‌بندی مدل شبکه عصبی مصنوعی ارائه شده است. درصد پیش‌بینی درست داده‌های آموزش و آزمایش نیز به‌طور مجزا در ستون آخر اشاره شد.

جدول ۵ - مقایسه مدل‌های شبکه عصبی مصنوعی با معماری‌های مختلف

| لایه‌های پنهان | | | | سطح عدم تطابق |
|----------------|----------|----------|----------|---------------|
| تعداد لایه | لایه اول | لایه دوم | لایه سوم | |
| ۲ | ۱۰ | ----- | ----- | ۰/۱۷۱۶ |
| ۳ | ۶ | ۲ | ----- | ۰/۱۲۶۹ |
| ۳ | ۳ | ۳ | ----- | ۰/۱۵۳۱ |
| ۳ | ۹ | ۴ | ----- | ۰/۱۶۱۷ |
| ۳ | ۱۰ | ۵ | ----- | ۰/۱۶۰۴ |
| ۳ | ۱۰ | ۶ | ----- | ۰/۱۹۰۳ |
| ۳ | ۶ | ۷ | ----- | ۰/۱۶۷۹ |
| ۳ | ۳ | ۸ | ----- | ۰/۱۳۴۳ |
| ۳ | ۸ | ۹ | ----- | ۰/۱۶۴۲ |
| ۳ | ۹ | ۱۰ | ----- | ۰/۱۵۱۶ |
| ۴ | ۶ | ۲ | ۲ | ۰/۱۷۹۱ |
| ۴ | ۷ | ۲ | ۳ | ۰/۱۷۵۴ |
| ۴ | ۸ | ۲ | ۴ | ۰/۱۸۷۹ |
| ۴ | ۵ | ۳ | ۵ | ۰/۱۷۵۰ |
| ۴ | ۴ | ۴ | ۶ | ۰/۱۸۵۷ |
| ۴ | ۷ | ۶ | ۷ | ۰/۱۷۶۹ |
| ۴ | ۳ | ۵ | ۸ | ۰/۱۶۹۸ |
| ۴ | ۲ | ۷ | ۹ | ۰/۱۸۹۲ |
| ۴ | ۸ | ۴ | ۱۰ | ۰/۱۸۹۶ |

(منبع: یافته‌های حاصل از پژوهش)

- 1- Root Mean Square Error
- 2- Confusion matrix

داده‌های آموزش در اینجا نیز همان داده‌های آموزشی است که در مدل رگرسیون لجستیک استفاده شده که شامل ۲۶۶ مشتری است و از این میان، ۱۹۶ مشتری خوش‌حساب و ۷۰ مشتری بدحساب می‌باشند. مدل پیشنهادی شبکه عصبی مقاله حاضر در پیش‌بینی مشتریان بدحساب ۶۵/۷ درصد و در پیش‌بینی مشتریان خوش‌حساب ۹۵/۴ درصد درست عمل کرده است و دقت کل مدل رگرسیون در طبقه‌بندی مشتریان خوش‌حساب و بدحساب ۸۷/۶ درصد بوده است. مدل شبکه عصبی مصنوعی که با ۸۰ درصد داده‌ها آموزش دیده است توسط داده‌های جدیدی (۲۰ درصد مابقی داده‌ها) مورد آزمایش قرار می‌گیرد. در مجموعه آزمایش ۶۸ مشتری وجود دارد که ۴۲ نفر خوش‌حساب و ۲۶ نفر بدحساب می‌باشند. مدل پیشنهادی در برآورد داده‌های آزمایش دقت ۶۹/۱۱ درصدی داشته است به‌گونه‌ای که در پیش‌بینی مشتریان خوش‌حساب ۷۸/۵۷ درصد و مشتریان بدحساب ۵۳/۸ درصد درست پیش‌بینی کرده است.

جدول ۶- نتایج طبقه‌بندی مدل شبکه عصبی مصنوعی

| داده‌ها | واقعی | پیش‌بینی | | % صحت |
|-----------------|----------|----------|----------|-------|
| | | بدحساب | خوش‌حساب | |
| داده‌های آموزش | بدحساب | ۴۶ | ۲۴ | ۶۵/۷ |
| | خوش‌حساب | ۹ | ۱۸۷ | ۹۵/۴ |
| | | ۲۰/۶۷ | ۷۹/۳۳ | ۸۷/۶ |
| داده‌های آزمایش | بدحساب | ۱۴ | ۱۲ | ۵۳/۸ |
| | خوش‌حساب | ۹ | ۳۳ | ۷۸/۵۷ |
| | | ۳۳/۸۲ | ۶۶/۱۷ | ۶۹/۱۱ |

(منبع: یافته‌های حاصل از پژوهش)

بحث و مقایسه مدل‌های کلاسیک و شبکه عصبی

در مباحث حوزه اعتبارسنجی و طبقه‌بندی متقاضیان در تصمیمات اعتباری دو نوع خطای طبقه‌بندی وجود دارد: خطای نوع اول (I) و خطای نوع دوم (II). خطای نوع اول زمانی رخ می‌دهد که مشتریانی که واقعاً خوش‌حساب هستند جزء گروه بدحساب طبقه‌بندی شوند و خطای نوع دوم زمانی رخ می‌دهد که مشتریان بدحساب به اشتباه خوش‌حساب تلقی گردند و به آن‌ها وام تعلق گیرد. بدیهی است زمانی که به مشتری بدحسابی که اشتبهاً خوش‌حساب شناسایی شده وام تعلق گیرد نسبت به زمانی که یک مشتری خوش‌حساب که اشتبهاً بدحساب شناخته شده و از دریافت وام محروم

مانده است، هزینه و تبعات منفی سنگین تری به همراه خواهد داشت. بنابراین به طور خلاصه می توان گفت خطای نوع دوم نسبت به خطای نوع اول هزینه و پیامدهای بیشتری خواهد داشت.

در این پژوهش پس از ارائه مدل رگرسیون لجستیک و شبکه عصبی مصنوعی، اعتبار مدل های حاصل از این تحقیق در شرایط واقعی برای ۶۸ نمونه از مشتریان که اطلاعات آنها در فرایند یادگیری شبکه نقشی نداشته اند، اجرا شده است تا وضعیت اعتیاری مشتریان مورد نظر را بررسی نماید (این داده ها همان داده های سنجش عملکرد است که ۲۰ درصد داده های کل را تشکیل می دهد). از آنجایی که شبکه عصبی و رگرسیون لجستیک الگوی رفتار اعتباری مشتریان را از طریق ۸۰ درصد داده ها آموزش دیده اند و سپس آزمایش نموده است و در نهایت خطای خود را با همین داده ها بهبود داده است بنابراین با ورود داده های جدید می توان دقت مدل ساخته شده در دنیای واقعی را تخمین زد. همان طور که در جدول (۷) اشاره شده است مدل شبکه عصبی مصنوعی در داده های آزمایش دقت ۶۹/۱۱ درصدی داشته که نسبت به رگرسیون لجستیک با دقت ۵۴/۴ درصد، تقریباً ۱۵ درصد بهتر عمل کرده است. خطای نوع اول در این مدل نسبت به رگرسیون لجستیک ۱۷ درصد کاهش یافته است و خطای نوع دوم نیز به میزان ۱۲ درصد کاهش یافته و عملکرد بهتری داشته است.

جدول ۷- خطای نوع اول و دوم در مدل های طبقه بندی

| خطای نوع دوم | خطای نوع اول | دقت طبقه بندی | مدل طبقه بندی |
|--------------|--------------|---------------|------------------|
| ۴۶/۱۵ | ۲۱/۴۲ | ۶۹/۱۱ | شبکه عصبی مصنوعی |
| ۵۷/۶۹ | ۳۸/۱ | ۵۴/۴ | رگرسیون لجستیک |

(منبع: یافته های حاصل از پژوهش)

نتیجه گیری

با توجه به اهمیت تخصیص صحیح اعتبار در بانکها در این مقاله سعی گردید یک مدل مناسب برای ارزیابی وضعیت اعتباری متقاضیان وام پیش از اعطای تسهیلات طراحی گردد. در این راستا، مدل های شبکه عصبی و کلاسیک مورد استفاده قرار گرفت تا کاراترین آنها برای دستیابی به این هدف انتخاب گردد؛ با مقایسه عملکرد مدل شبکه عصبی و رگرسیون لجستیک در برآورد وضعیت اعتباری متقاضیان، نتایج نشان داد که دقت مدل شبکه عصبی نسبت به رگرسیون لجستیک به میزان ۱۵

درصد بیشتر است و از سویی خطای نوع اول و دوم در شبکه عصبی به ترتیب ۱۷٪ و ۱۲٪ کمتر است. با توجه به اهمیت بالای خطای نوع دوم در تصمیمات اعتباری که در نتیجه بروز آن، حجم مطالبات معوق افزایش می‌یابد، در این پژوهش شبکه عصبی مصنوعی در مقایسه با روش کلاسیک به میزان قابل‌ملاحظه‌ای سطح این خطا را کاهش داده است و در همین راستا حجم مطالبات معوق بانک نیز به میزان چشمگیری کاهش خواهد یافت؛ بنابراین می‌توان اظهار نمود که مدل شبکه عصبی مصنوعی در این پژوهش کارا تر عمل نموده است و می‌تواند بر اساس متغیرهای کیفی و مالی، مشتریان حقیقی بانک را از نظر ریسک اعتباری دسته‌بندی نماید. از طرفی با توجه به قابلیت شبکه عصبی در مدلسازی رفتار پدیده مورد بررسی، می‌توان پیشنهاد کرد موسسات مالی، بانکها و به ویژه بانک مورد مطالعه، این سیستم اعتبارسنجی را در قالب یک سیستم پشتیبان تصمیم برای ارزیابی وضعیت اعتباری متقاضیان تسهیلات بکار گیرند، چرا که با توجه به قابلیت یادگیری مدل‌های مبتنی بر هوش مصنوعی، با گذر زمان و کسب تجربیات جدید، توانایی و قابلیت سیستم در پیش‌بینی صحیح وضعیت اعتباری مشتریان افزایش خواهد یافت و این موجب کاهش بیشتر خطاهای انسانی و جلوگیری از فرایند قضاوتی کارشناسان و همچنین پاسخگویی سریع‌تر به متقاضیان تسهیلات اعتباری خواهد شد.

با توجه به نتایج پژوهش حاضر پیشنهادهای ذیل برای تحقیقات آتی ضروری به نظر می‌رسد:

- ارائه مدل‌های امتیازدهی اعتباری که قادر به تعیین میزان تسهیلات اعتباری قابل پرداخت به مشتریان (با توجه به ریسک آنها) باشد.
- اعتبارسنجی مشتریان حقوقی با استفاده از شبکه عصبی مصنوعی.

منابع و مأخذ

- 1- Ekrami, M. & Rahnama Aski, Azadeh(2009). Investigation the risk factors of past due receivables and deferred Bank. Economic Research Special Bank, 6, 195-216.
- 2- Alborzi, M., Mohammad Pourzarandi, M., khanbabaie, M. (2010). Using Genetic Algorithm in Optimizing Decision Trees for Credit Scoring of Banks Customers. Journal of Information Technology Management, 2(4), 23-38.
- 3- Taghavifard, M., Nadali, A. (2012). Classification of Credit Applicants of Banking Systems Using Data Mining and Fuzzy Logic. Industrial Management Studies, 9(25), 85-107.

- 4- jalili, M., Khodaei valah zadgharad, M. & Koneshlou, M. (2010). real customers Credit scoring in the banking system, Quantitative studies in management, 1 (3), 127-148.
- 5- Dehmordeh, N., Shahraki, J., Seyfoddinpoor, S. & Esfandiyari, M. (2013). Loan Customers Validation Using Credit Scoring model (Case Study : Sepah Bank Branches Zahedan). Management Researches, 5(18), 135-152.
- 6- Rjabzadeh ghatari, A., Ahmadi, P. & Mirzaei, A. B. (2009). Designing an Intelligent Combined System for Credit scoring of Bank Customers Using Mixed Fuzzy Argument Models, 53, 195-201.
- 7- Mirtalaei, M., Azadeh, M. A., Saberi, M. & Ashjari, B. (2010). Hybrid Intelligent Credit Ranking System Using Fuzzy Hybrid-Reasoning Models. Iranian Journal of Trade Studies, 14(53), 159-201.
- 8- Abdou, H. A., Alam, S. T., & Mulkeen, J. (2014). Would credit scoring work for Islamic finance? A neural network approach. International Journal of Islamic and Middle Eastern Finance and Management, 7(1), 112-125.
- 9- Abdou, H. A. (2009). An evaluation of alternative scoring models in private banking. The Journal of Risk Finance, 10, 38-53.
- 10- Abdou, H. A., & Pointon, J. (2009). Credit scoring and decision m-aking in Egyptian public sector Banks. International Journal of Managerial Finance, 5(4), 391-406.
- 11- Abdou, H. A., & Pointon, J. (2011). Credit scoring, statistical techniques and evaluation criteria: a review of the literature. Intelligent Systems in Accounting, Finance & Management, 18 (2-3), 59-88.
- 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- Bekhet, H. A., & Eletter, S. F. K. (2014). Credit risk assessment model for Jordanian commercial banks: Neural scoring approach. Review of Development Finance, 4(1), 20-28.
- 14- Dimitriu, M., Avramescu, E.A., & Caracota, R. C. (2010). Credit scoring for individuals, *Economia. Seria Management*, 13(2), 361-377.
- 15- Dong, G., Lai, K. K., & Yen, J. (2010). Credit scorecard based on logistic regression with random coefficients. *Procedia Computer Science*, 1(1), 2463-2468.
- 16- Einav, L., Jenkins, M., & Levin, J. (2013). The impact of credit scoring on consumer lending. *The RAND Journal of Economics*, 44(2), 27-249.
- 17- Fogarty, D. J. (2012). Using Genetic Algorithms for Credit Scoring System Maintenance Functions. *International Journal of Artificial Intelligence & Applications*, 3(6).
- 18- Harris, T. (2015). Credit scoring using the clustered support vector machine. *Expert Systems with Applications*, 42(2), 741-750.
- 19- Hui, L., Li, S., & Zongfang, Z. (2013). The Model and Empirical Research of Application Scoring based on Data Mining Methods. *Procedia Computer Science*, 17, 911-918.
- 20- Kozeny, V. (2015). Genetic algorithms for credit scoring: Alternative fitness function performance comparison. *Expert Systems with Applications*, 42(6), 2998-3004.
- 21- Lee, T.S., & Chen, I. F. (2005). A two-stage hybrid credit scoring model using artificial neural networks and multivariate adaptive regression splines. *Expert Systems with Applications*, 28, 743-752.

- 22- Li, X. L., & Zhong, Y. (2012). An overview of personal credit scoring: techniques and future work, *International Journal of Intelligence Science*, 2, 181-189.
- 23- Liu, Y. (2001). New issue in credit scoring application. *Nr Arbeitsbericht*, 16, 1-35.
- 24- Lu, H., Liyan, H., & Hongwei, Z. (2013). Credit scoring model hybridizing artificial intelligence with logistic regression. *Journal of Networks*, 8(1), 253-261.
- 25- Marques, A. I., García, V., & Sanchez, J. S. (2012). A literature review on the application of evolutionary computing to credit scoring. *Journal of the Operational Research Society*, 64(9), 1384-1399.
- 26- Nguyen, H. T. (2014). Credit Scoring—An empirical study involving auto loans within GE Money Bank France, 1-16.
- 27- Nicula, I. (2013). Some Aspects Concerning the Measurement of Credit Risk. *Procedia Economics and Finance*, 6, 668-674.
- 28- Nurlybayeva, K., & Balakayeva, G. (2013). Algorithmic Scoring Models. *Applied Mathematical Sciences*, 7(12), 571-586.
- 29- Sarlija, N., Bencic, M., & Zekic-Susac, M. (2006). Modeling customer revolving credit scoring using logistic regression, survival analysis and neural networks. *The 7th WSEAS International Conference on Neural Networks, Cavtat, Croatia*, 12-14 June, 164-169.
- 30- Šušteršič, M., Zupan, J., & Mramor, D. (2009). Consumer credit scoring models with limited data. *Expert Systems with Applications*, 36, 4736-4744.
- 31- West, D. (2000). Neural Network Credit Scoring Models. *Computers and Operations Research*, 27, 1131-1152.
- 32- Yu, L., Wang, S., Lai, K. K., & Zhou, L. (2008). *Bio-inspired credit risk analysis: computational intelligence with support vector machines*. Springer
- 33- 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.