

ارائه الگوریتم هوشمند مبتنی بر اعتماد جهت تعیین اعتبار مشتریان یک سیستم مالی

منیره السادات میرطالایی^{۱*}، محمدعلی آزاده^۲، مرتضی صابری^۳ و بهزاد اشجری^۴

^۱ دانش آموخته کارشناسی ارشد مهندسی صنایع - دانشگاه تفرش

^۲ دانشیار گروه مهندسی صنایع - پردیس دانشکده‌های فنی - دانشگاه تهران

^۳ مربی گروه مهندسی صنایع - دانشگاه تفرش

^۴ استادیار گروه مهندسی صنایع - دانشگاه تفرش

(تاریخ دریافت ۹۰/۷/۱۸، تاریخ دریافت روایت اصلاح‌شده ۹۰/۸/۱۱، تاریخ تصویب ۹۱/۱/۱۹)

چکیده

مدل‌های اعتبارسنجی با دریافت مجموعه‌ای از اطلاعات مشتری به عنوان ورودی، امتیازی را به عنوان خروجی به مشتری اختصاص می‌دهند که بانک‌ها از این امتیاز می‌توانند در راستای تخصیص اعتبار به مشتری بهره‌گیرند. اغلب مدل‌های ارائه‌شده در این زمینه، مشتریان را با عنوان دو گروه "خوش حساب" و "بد حساب" دسته‌بندی می‌کنند. از این رو، احتمال گرفتن تصمیمات ناعادلانه در حوزه واگذاری اعتبار به مشتریان افزایش می‌یابد. با توجه به اهمیت اعتماد در تجارت الکترونیک، هدف در این تحقیق آن است تا با بهره‌گیری از شبکه عصبی مصنوعی و با تلفیق این دو مفهوم (اعتماد و اعتبارسنجی)، امکان لحاظ کردن سطح اعتماد متقاضیان در فرآیند اعطای وام به آن‌ها، برای مؤسسات مالی فراهم شود. در این پژوهش برای نخستین بار، به کاربرد مفهوم اعتماد در مدل‌های اعتبارسنجی پرداخته شده است که می‌تواند راهگشای استفاده از روشی نوین در فرآیند واگذاری اعتبار آنلاین در سیستم بانکداری باشد و از طرف دیگر با تقسیم‌بندی مشتریان به گروه‌های بیشتر، امکان اعمال سیاست‌هایی متناسب با هر گروه برای بانک‌ها فراهم شود.

واژه‌های کلیدی: اعتبارسنجی، شبکه عصبی مصنوعی، اعتماد

مقدمه

صورت کامل پرداخت کنند. در مقابل، مشتریان "بد حساب" به کسانی اطلاق می‌شود که بانک برای وصول مطالبات دریافت شده توسط آن‌ها با مشکل روبه‌رو خواهند شد.

نظام امتیازدهی اعتباری، برای اولین بار در دهه ۱۹۵۰ تدوین شد. در واقع، ایده ایجاد تمایز بین گروه‌های موجود در یک جامعه بر اساس مشخصه‌های ذکر شده برای اعضای آن، از مقاله فیشر^۱ (۱۹۳۶) نشأت می‌گیرد. دانهام^۲ در سال ۱۹۳۸، اولین کسی بود که سیستمی را برای ارزیابی متقاضیان تسهیلات ارائه کرد. دوران^۳ در سال ۱۹۴۱، به شناسایی عوامل مهم از دید وام‌دهندگان پرداخت. او اولین کسی بود که دیدگاه آماری را مد نظر قرار داد و از مدل تحلیل تمایزی که بر نتایج فیشر متمرکز بود استفاده کرد. بدین وسیله عملاً وی انگیزه توسعه چارچوب تئوریک که بدان وسیله بتوان اهمیت هر معیار مشخص را تعیین کرد به وجود آورد. بنابراین

ارزیابی ریسک اعتباری، یکی از مسائل مهم و پرچالش در زمینه تحلیل‌های مالی به شمار می‌آید. زیرا از این طریق می‌توان از وارد آمدن خسارات کلان که پیامد تصمیمات نادرست واگذاری اعتبار (وام) به متقاضیان است، تا اندازه زیادی اجتناب کرد [۱]. از طرف دیگر، در صورت گرفتن تصمیمات صحیح در این زمینه، سود حاصل از وام‌های واگذار شده، بخشی از درآمد این مؤسسات را تشکیل خواهد داد. تحقیقات نشان داده‌اند که با وجود سرویس‌های مختلفی که به تازگی توسط بانک‌ها ارائه شده‌اند، واگذاری وام به مشتریان حقیقی و حقوقی هنوز هم به عنوان یکی از مهم‌ترین منابع درآمد برای بانک‌ها و مؤسسات مالی محسوب می‌شود. بنابراین موضوع اصلی برای هر وام‌دهنده، تفکیک مشتریان "خوش حساب" از "بد حساب"، قبل از اعطای وام به آن‌ها است. منظور از مشتریان "خوش حساب"، آن دسته از متقاضیان اعتبار است که اصل و سود مطالبات دریافتی را به موقع و به

است. تحقیقات گسترده‌ای که در زمینه کاربردهای شبکه عصبی در عرصه تجارت انجام شده است، حکایت از نتایج موفقیت‌آمیز این ابزار در حل مسائل با روابط غیرخطی، در مقایسه با تکنیک‌های آماری داشته است. در واقع توانایی شبکه عصبی در بازشناسی روابط غیرخطی موجود میان متغیرها، منجر به محبوبیت بیشتر آن در مسائل تعیین و پیش‌بینی ریسک اعتباری در مقایسه با روش‌های پارامتریک (مانند تحلیل تمایزی خطی و آنالیز رگرسیون خطی) و ناپارامتریک (مانند نزدیک‌ترین همسایه و درخت تصمیم) شده است [۱۳].

شبکه عصبی در اواخر دهه ۱۹۵۰ معرفی شد، اما اولین کاربرد این تکنیک در زمینه اعتبارسنجی به اوایل ۱۹۹۰ برمی‌گردد.

به طور ویژه، مدل شبکه عصبی با الگوریتم یادگیری پس انتشار^{۱۳}، بخ دلیل توانایی بی‌نظیرش در طبقه‌بندی داده‌ها، از پرکاربردترین ابزار در تصمیم‌گیری‌های مالی به شمار می‌آید [۱۷]. مدل‌های شبکه عصبی، بالاترین میانگین نرخ طبقه‌بندی صحیح را در مقایسه با روش‌های تحلیل تمایزی و رگرسیون لجستیک دارد؛ اگرچه در برخی موارد نتایج آن‌ها بسیار به هم نزدیک هستند [۴]. مقیاس‌های آماری مرتبط نشان می‌دهند که مدل‌های شبکه عصبی نسبت به درخت طبقه‌بندی و رگرسیون (CART) و رگرسیون لجستیک، توصیف‌کننده‌های بهتری برای داده‌ها هستند [۶]؛ در حالی که اغلب، تحلیل تمایزی، قابلیت بیشتری در زمینه طبقه‌بندی داده‌ها در مقایسه با پیش‌بینی آن‌ها دارد، رگرسیون لجستیک توانایی پیش‌بینی بهتری دارد [۱۸]. تحقیقات حتی تا سطح مقایسه نتایج شبکه‌های پیش‌نگر^{۱۴} و پس‌انتشار نیز گسترده شدند [۱۹]. همانند شبکه‌های عصبی و تکنیک‌های پیشرفته آماری، از مدل‌های هیبریدی نیز در ساخت الگوریتم‌های اعتبارسنجی استفاده می‌شوند [۵]، [۲۰].

عمده مطالعات انجام‌شده در این زمینه، به دنبال ارائه راه‌حلی برای افزایش دقت مدل‌های موجود هستند. اکثر این روش‌ها، مشتریان را با دو عنوان "خوش‌حساب" (Good credit) و "بدحساب" (Bad credit) دسته‌بندی می‌کنند. نظر به این که با استفاده از مدل‌های موجود، احتمال گرفتن تصمیمات نادرست و تا حدودی ناعادلانه

می‌توان دوراند را پایه‌گذار سیستم اعتباردهی امروزی دانست. حجم زیاد تقاضای اعتباری، منجر به استفاده از مدل‌های اعتبارسنجی در مؤسسات مالی شد [۲]. با رشد سریع صنعت اعتباردهی و مدیریت پرتفولیوی وام‌های بزرگ، از مدل‌های اعتبارسنجی به طور گسترده‌ای، در فرآیند ارزیابی پذیرش درخواست‌های وام استفاده شد.

به طور کلی، عمده مدل‌های اعتبارسنجی، در یکی از دو گروه زیر قرار می‌گیرند: روش‌هایی که از تکنیک‌های آماری برای طبقه‌بندی داده‌ها استفاده می‌کنند و گروه دیگر که از ابزار هوش مصنوعی در این زمینه بهره می‌برند. روش‌های آماری متعارفی که در زمینه ارزیابی اعتبار استفاده شده‌اند، عبارتند از: رگرسیون لجستیک (LR^4)، [۳]، [۴]، [۵]، تحلیل تمایزی (DA^5)، [۳]، [۴]، [۵]، نزدیک‌ترین همسایه^۶ [۳]، آنالیز پروبیت^۷ (PA) [۴] و درخت طبقه‌بندی و رگرسیون ($CART^8$) [۶].

استفاده از تکنیک‌های آماری، مستلزم شناخت و تحلیل روابط بین متغیرها است که در مسائلی با ابعاد زیاد، مشکل‌آفرین خواهد بود [۷]. از سوی دیگر، بهره‌گیری از این روش‌ها با محدودیت‌هایی همراه است که از آن جمله می‌توان به فرض وجود روابط خطی میان متغیرها (که در تضاد با واقعیت است) در برخی روش‌های مرسوم اشاره کرد. از طرفی، روش‌های آماری غیرخطی مانند MARS^۹، نیازمند انتخاب یک مدل بر پایه روش آزمون و خطا هستند [۸]. با این وجود، مقایسه بین تکنیک‌های مرسوم و پیشرفته آماری هنوز هم موضوع بسیاری از مطالعات است [۵]، [۹]، [۱۰].

از شبکه عصبی مصنوعی^{۱۱} [۴]، [۵]، الگوریتم ژنتیک^{۱۱} [۱۲]، [۱۳] و ماشین بردار پشتیبانی^{۱۲} [۳]، [۱۲]، می‌توان به عنوان تکنیک‌های هوش مصنوعی که به طور گسترده‌ای در مسائل ارزیابی اعتباری به کار رفته‌اند، اشاره کرد.

شبکه عصبی مصنوعی، در چند سال اخیر توجه بسیاری از دانشمندان و محققان را به خود جلب کرده و نتایج شگفت‌انگیزی در حل مسائل مختلف، در زمینه‌های متفاوت ارائه داده است. قدرت خارق‌العاده شبکه عصبی در پیش‌بینی، ناشی از توانایی آن در شبیه‌سازی هوش انسان [۱۴]، و قابلیت شگرف آن در تشخیص الگوها [۱۰]، [۱۵]

جدول ۱: خلاصه‌ای از مطالعات انجام شده در زمینه‌ی اعتبارسنجی

Statistical Approaches	Artificial Intelligence Approaches
<ul style="list-style-type: none"> • Logistic Regression [3,4,5,21] • Discriminant Analysis[3,4,5,21] • K-Nearest Neighbours[3] • Probit Analysis[4] • Classification And Regression Tree[6] 	<ul style="list-style-type: none"> • Artificial Neural Network [4,5,11,22] • Genetic Algorithm [12,13] • Support Vector Machine [3,12]

در مقاله [۲۶]، برای ارزیابی میزان قابلیت اعتماد، معیاری ۷ سطحی، هم به صورت عددی و هم غیر عددی در نظر گرفته شده است. در اینجا ضمن توصیف هر سطح، مفاهیم (تعاریف زبانی) آن نیز مورد بحث قرار خواهد گرفت. تعریف زبانی هر سطح، بیانگر مفهوم اطمینان یا اعتماد عامل اعتمادکننده به عامل مورد اعتماد است. با ورود سیستم‌های ارزیابی و اعطای اعتبار در عرصه تجارت آنلاین، خطر پدید آمدن خسارات ناشی از نبود تقارن اطلاعات بین بانک‌ها و متقاضیان، بیش از پیش احساس می‌شود. بنابراین، با توجه به اهمیت اعتماد در تجارت الکترونیک، هدف در این تحقیق آن است تا با بهره‌گیری از شبکه عصبی مصنوعی و با تلفیق این دو مفهوم (اعتماد و اعتبارسنجی)، امکان لحاظ کردن سطح اعتماد متقاضیان در فرآیند اعطای وام به آن‌ها، برای مؤسسات مالی فراهم شود.

در راستای پیشینه کاربرد مفهوم اعتماد در مدل‌های ارزیابی اعتباری، با توجه به بررسی‌های به عمل آمده، می‌توان اذعان داشت که تا کنون هیچ مدلی برای تلفیق این دو مفهوم ارائه نشده است؛ بنابراین این مطالعه می‌تواند شروع فصل جدیدی از تحقیقات در این زمینه باشد.

مدل اعتبارسنجی مبتنی بر مفهوم اعتماد

همانگونه که قبلاً اشاره کردیم، هدف اصلی از معرفی الگوریتم پیشنهادی، استفاده از مفهوم اعتماد در زمینه اعتبارسنجی و سهولت فرآیند سیاست‌گذاری اعطای اعتبار به مشتریان است. ساختار اصلی این رویکرد هوشمند در ادامه توضیح داده می‌شود. شکل (۱)، گام‌های الگوریتم پیشنهادی را نشان می‌دهد.

گام اول: تعیین ورودی‌ها و خروجی

انتخاب مجموعه مشاهدات به عنوان اولین گام متدولوژی پیشنهادی، انجام می‌شود. مشخصه‌ها یا

در زمینه اعطای اعتبار به متقاضیان افزایش می‌یابد، ارائه مدلی که از توانایی دسته‌بندی مشتریان (از نظر اعتباری) به گروه‌های بیشتر برخوردار باشد، ضروری به نظر می‌رسد. از طرف دیگر، تعداد زیادی از مدل‌های پیشنهادشده، به وجود روابط غیرخطی میان متغیرهای ورودی و متغیر خروجی در مسائل ارزیابی اعتبار، توجه چندانی نداشته‌اند، و گاهی نیز در صورت وجود متغیرهای زیاد در مسئله، کارایی مطلوبی ندارند.

در جدول (۱)، خلاصه‌ای از مدل‌های موجود در حوزه اعتبارسنجی، به تفکیک استفاده از تکنیک‌های آماری و هوش مصنوعی ارائه شده است.

امروزه، اعتماد، یکی از عوامل اساسی در موفقیت تجارت الکترونیک به شمار می‌آید. این مفهوم توجه بسیاری از کاربران وب سایت‌ها را به خود جلب کرده است [۲۳]. در سال‌های اخیر، بخش قابل توجهی از مطالعات به ارائه مکانیزمی بر پایه اعتماد و شهرت^{۱۵}، برای تسهیل فرآیند شکل‌گیری معاملات پیچیده در عرصه تجارت الکترونیک اختصاص یافته است [۲۳]. اعتماد، در واقع باور و اعتقاد عامل اعتمادکننده^{۱۶} به توانایی و تمایل عامل مورد اعتماد^{۱۷} در عملکرد مطابق با انتظاراتی است که قبلاً توافق شده‌اند [۲۴]. در [۲۵]، قابلیت اعتماد به عنوان یک مقدار عددی تعریف شده است که نمایانگر شدت اعتماد عامل اعتمادکننده به عامل مورد اعتماد، در یک برهه زمانی و در زمینه‌ای معین است. منظور از عامل اعتمادکننده و عامل مورد اعتماد، فرد، افراد یا گروه‌هایی است که می‌تواند متشکل از خانواده‌ها، همسایه‌ها، سازمان‌ها یا حتی جوامع باشد.

در این مطالعه ما از تعریف ارائه‌شده در [۲۶] بهره

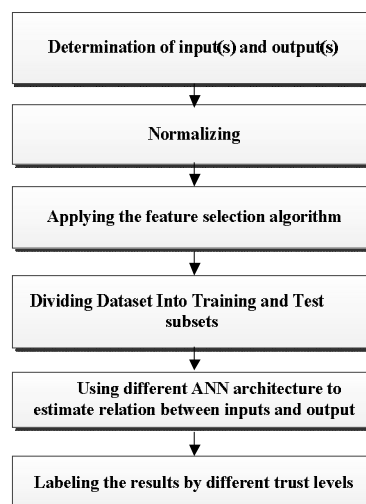
می‌بریم:

" اعتماد، به عنوان باور و اعتقاد عامل اعتمادکننده، به تمایل و توانایی عامل مورد اعتماد، در ارائه خدمات توافق‌شده در زمینه و برهه زمانی خاصی است."

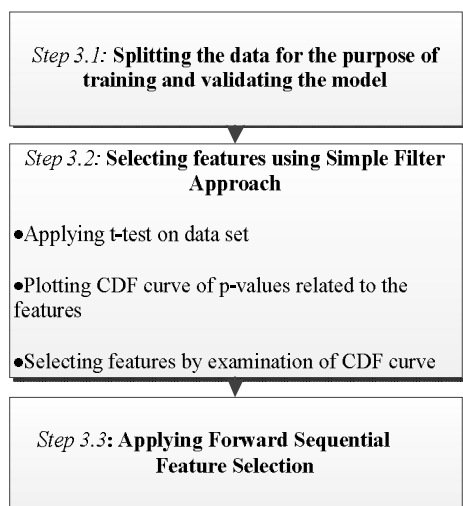
گام سوم: کاربرد الگوریتم گزینش مشخصه‌های کلیدی

کاهش تعداد ویژگی‌های (متغیرهای پیش‌بینی‌کننده)، یک پارامتر تأثیرگذار در طراحی مدل داده‌کاوی به شمار می‌آید. اغلب تعدد ویژگی‌ها در مجموعه داده‌هایی با تعداد محدودی از مشاهدات، عامل مطلوبی برای تولید مدل داده‌کاوی نیست؛ زیرا ممکن است که الگوریتم یادگیری، در مواجهه با نویز، شروع به حفظ کردن کند و از مطلوبیت نهایی مدل بکاهد. در نتیجه کاهش تعداد ویژگی‌ها علاوه بر کاهش زمان محاسبات، منجر به افزایش قابلیت تعمیم‌پذیری مدل داده‌کاوی روی مجموعه داده آزمون نیز، می‌شود. در این مطالعه، کاهش ابعاد مسئله از طریق سه مرحله (شکل ۲) انجام می‌پذیرد.

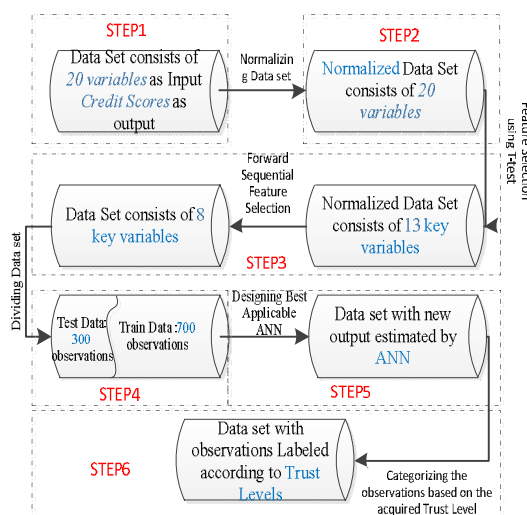
متغیرهای پیش‌بینی‌کننده به عنوان ورودی‌ها تعریف شده‌اند و خروجی، گروه (یا امتیازی) است که به هر مشاهده اختصاص می‌یابد.



شکل ۱: ساختار الگوریتم پیشنهادی برای رویکرد مبتنی بر اعتماد



شکل ۳: ساختار پیشنهادی برای گزینش مشخصه‌های کلیدی



شکل ۲: فلوجارت شرح مدل پیشنهادی

گام ۳-۱:

کارآیی روی مجموعه آموزشی، تخمین خوبی برای کارآیی مدل روی یک مجموعه آزمون مستقل نیست. کارآیی روی مجموعه آموزشی اغلب خیلی خوشبینانه است. برای پیش‌بینی کارآیی یک مدل، لازم است که کارآیی آن، روی مجموعه داده دیگری که در ساخت مدل استفاده نشده است، تعیین شود. به همین منظور، مجموعه داده به دو گروه تقسیم می‌شود: گروه آموزش که شامل داده‌هایی است که فقط برای ساخت مدل به کار گرفته می‌شوند، و گروه آزمون (آزمایش) که به منظور سنجش کارآیی مدل است.

گام دوم: نرمالیزه کردن داده‌ها

از آن جایی که ممکن است مجموعه داده‌ها، شامل متغیرهایی با مقادیر بسیار بزرگ یا کوچک باشد، برای برطرف کردن اثر احتمالی تسلط متغیرها با مقادیر بزرگ بر سایر متغیرها، ابتدا رکوردهای هر متغیر را طبق رابطه زیر نرمالیزه می‌کنیم تا همه رکوردها در بازه [۰ ۱] قرار گیرند:

$$X_{\text{normalized}} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (1)$$

گام ۳-۲:

در این بخش هدف، کاهش ابعاد مسئله از طریق انتخاب چند مشخصه کلیدی از مجموع متغیرهای پیش‌بینی کننده است، به گونه‌ای که بهترین عملکرد در زمینه طبقه‌بندی داده‌ها حاصل شود. اغلب الگوریتم‌های گزینش مشخصه‌های کلیدی به دو گروه تقسیم می‌شوند: روش‌های فیلتر که با تکیه بر مشخصات کلی مجموعه داده و بدون استفاده از روش آموزشی، زیر مجموعه‌هایی از مجموعه داده را انتخاب و ارزیابی می‌کنند.

روش‌های *Wrapper* که از کارایی الگوریتم یادگیری برای ارزیابی زیرمجموعه ویژگی‌ها استفاده می‌کنند. در این روش، جستجو برای یافتن ویژگی‌هایی صورت می‌گیرد که در بهترین تناسب با الگوریتم آموزشی باشند. این روش در مقایسه با روش بالا سرعت کمتری دارد.

از فیلترها، به علت سرعت و سادگی کاربردشان، اغلب در مرحله پیش‌پردازش استفاده می‌شود. یکی از روش‌های فیلتر که در سطح وسیعی به کار گرفته شده است، استفاده از یک مقیاس تک متغیره روی هر یک از ویژگی‌ها به طور مجزا است، با فرض بر اینکه هیچ اثر متقابلی بین مشخصه‌ها وجود نداشته باشد. در اینجا آزمون فرض t را روی هر ویژگی به کار می‌بریم و مقادیر P -value حاصله از هر ویژگی را، به عنوان معیار موثر بودن آن ویژگی، در تفکیک کردن ریسک اعتباری به دو گروه خوب و بد، در نظر می‌گیریم.

برای اینکه بتوان یک تصور کلی از توانایی هر ویژگی در تفکیک کردن دو گروه به دست آورد، تابع توزیع تجمعی $(CDF)^{18}$ بر اساس مقادیر P -value رسم می‌شود. با بررسی منحنی CDF ، آن دسته از ویژگی‌ها که قدرت تفکیک‌کنندگی بیشتری دارند، مشخص خواهند شد. در صورت تمایل، می‌توان همه ویژگی‌ها را با توجه به P -value آن‌ها (یا قدرمطلق مقادیر آزمون t)، مرتب کرده و تعدادی از آن‌ها را به عنوان مشخصه‌های اصلی انتخاب کرد. هر چند، اغلب تصمیم‌گیری در مورد تعداد ویژگی‌های مورد نیاز کار سختی است، مگر در مواردی که فرد از دانش لازم در این زمینه بهره‌مند باشد، یا به دلیل وجود یک محدودیت خارجی، بیشترین تعداد ممکن ویژگی‌ها مشخص شده باشد.

گام ۳-۳:

هم اکنون مجموعه داده برای پیاده‌سازی الگوریتم اصلی گزینش مشخصه‌ها، یا به عبارتی روش گزینش ترتیبی رو به جلو $(FSFS)^{19}$ آماده است. مدل‌های انتخاب ویژگی ترتیبی، از پرکاربردترین تکنیک‌ها در این زمینه است. این مدل‌ها زیرمجموعه‌ای از ویژگی‌ها را، از طریق افزودن پیاپی (در جستجوی رو به جلو) یا حذف متوالی (در جستجوی رو به عقب) انتخاب می‌کنند تا مادامی که یکی از شرایط توقف الگوریتم به وقوع بپیوندد.

از آنجایی که یکی از اهداف متعارف در طبقه‌بندی داده‌ها، کمینه‌کردن مقدار MCE^20 (خطای طبقه‌بندی نادرست، یا به عبارتی نسبت تعداد مشاهداتی که در گروه نادرست واقع شده‌اند به تعداد کل مشاهدات) است، بنابراین فرآیند انتخاب ویژگی، یک جستجوی ترتیبی را به گونه‌ای انجام می‌دهد که از مقادیر MCE حاصل از به کارگیری الگوریتم یادگیری QDA^{21} روی هر یک از زیرمجموعه‌های کاندید، به عنوان مقیاس عملکرد آن زیرمجموعه استفاده کند. از گروه آموزش، برای انتخاب مشخصه‌ها و ساخت مدل QDA ، و از گروه آزمایش، برای ارزیابی عملکرد منتخب استفاده می‌شود. در طول فرآیند انتخاب مشخصه، برای ارزیابی و مقایسه عملکرد هر یک از زیرمجموعه‌های کاندید، واری اعتبار ۱۰ لایه‌ای 22 روی مجموعه آموزش پیاده می‌شود.

زمانی که الگوریتم گزینش مشخصه به کمترین مقدار برای خطای طبقه‌بندی نادرست برسد (یا به عبارتی اولین مینیمم محلی خود روی نمودار $CV MCE^{23}$)، متوقف می‌شود. گاه ممکن است که الگوریتم دچار توقف زود هنگام شود. برای حل این مشکل، می‌توان محدودیتی را به الگوریتم گزینش مشخصه اضافه کرد تا شرط توقف آن را، پس از بررسی همه ویژگی‌های منتخب قرار دهد.

گام چهارم: تقسیم مجموعه داده

مطابق با الگوریتم پیشنهادی، بعد از انتخاب موثرترین ویژگی‌ها، مجموعه داده را به دو زیرمجموعه آموزش و آزمایش تقسیم می‌کنیم. از گروه آموزش، برای محاسبه شیب و به روز کردن وزن‌ها و اربیبی شبکه استفاده می‌شود. در جریان فرآیند آموزش، میزان خطا در گروه آزمایش سنجیده می‌شود. میزان خطای ارزیابی اغلب همانند خطای گروه آموزش، در طول مرحله اول آموزش

در اینجا، مجموعه داده موجود، به گروه آموزش که شامل ۹۰٪ داده‌ها و گروه ارزیابی که مشتمل بر ۱۰٪ داده‌ها است، تقسیم شده است.

گام ۴-۲:

بعد از مرتب‌سازی داده‌های موجود، می‌توانیم نسبت مشتریان خوش‌حساب را بر کل مشاهدات (R_G)، پیدا کنیم. همین فرآیند، در مورد یافتن نسبت بدحساب‌ها در مقایسه با کل مجموعه داده (R_B) نیز، قابل اجرا است.

$$R_G = \frac{\text{تعداد مشتریان خوش حساب}}{\text{تعداد کل مشتریان}} \quad (۲)$$

$$R_B = \frac{\text{تعداد مشتریان بدحساب}}{\text{تعداد کل مشتریان}} \quad (۳)$$

گام ۴-۳:

این مرحله، با محاسبه مقادیر چهار تساوی زیر، انجام خواهد گرفت:

تعداد خوش‌حساب‌ها برای مجموعه آموزش = (تعداد کل مشتریان) * P_T * R_G (۴)

تعداد بدحساب‌ها برای مجموعه آموزش = (تعداد کل مشتریان) * P_T * R_B (۵)

تعداد خوش‌حساب‌ها برای مجموعه ارزیابی = (تعداد کل مشتریان) * P_V * R_G (۶)

تعداد بدحساب‌ها برای مجموعه ارزیابی = (تعداد کل مشتریان) * P_V * R_B (۷)

گام ۴-۴:

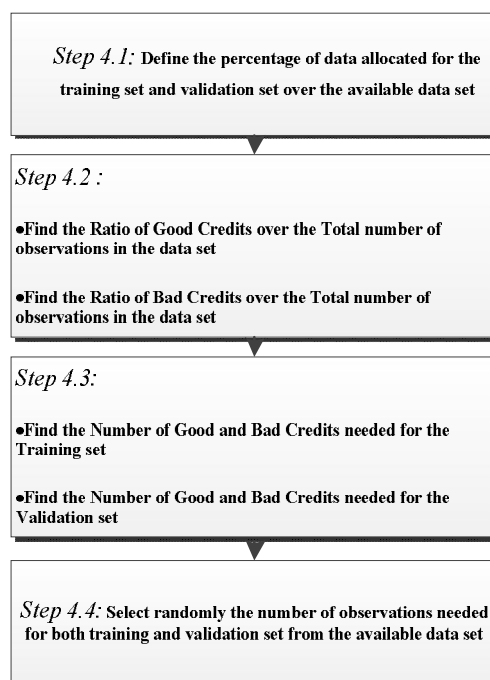
انتخاب مشتریان خوش‌حساب و بدحساب برای مجموعه‌های ارزیابی و آموزش، می‌تواند به طور تصادفی از مجموعه داده انجام پذیرد. به یاد داشته باشید که داده‌های ارزیابی باید مجزا از داده‌هایی باشند که برای آموزش مدل استفاده شده‌اند.

گام پنجم: ساخت مناسب‌ترین شبکه عصبی برای مجموعه داده‌ها

در ابتدا ساختار احتمالی برای شبکه ارائه می‌شود. سپس مدل‌های مختلف با استفاده از گروه آموزش اجرا شده و در نهایت کارایی آن‌ها با گروه آزمایش مورد ارزیابی قرار می‌گیرد. در میان شبکه‌های مختلف، شبکه‌های عصبی پیش‌نگر یا چند لایه‌ای (MLP)^{۲۴} از رایج‌ترین شبکه‌ها در تحقیقات مهندسی به شمار می‌آیند.

شبکه کاهش می‌یابد. مادامی که شبکه شروع به حفظ کردن داده‌ها می‌کند، اغلب خطا روی گروه آزمایش افزایش می‌یابد. زمانی که خطای آزمایش برای تعداد مشخصی از دوره‌ها افزایش می‌یابد، فرآیند آموزش متوقف شده و وزن‌ها و مقادیر اریبی شبکه به دوره‌ای با حداقل میزان خطا در آزمایش بازگردانده خواهد شد [۲۷]. داده‌هایی که برای آزمون به کار گرفته می‌شوند نباید در فرایند آموزش شبکه استفاده شده باشند و همچنین باید توصیف خوبی از گروه‌های موجود در مجموعه اصلی داده‌ها را ارائه دهند. به عبارت دیگر، نسبت مشتریان خوش‌حساب به مشتریان بدحساب در گروه آموزش و آزمون، باید همانند همین نسبت در مجموعه اصلی داده‌ها باشد. از طرف دیگر، باید بین اندازه گروه‌های آزمایش و آموزش توازن برقرار کرد.

برای سهولت کار، در ادامه، الگوریتمی برای تقسیم داده‌ها ارائه شده است.



شکل ۴: الگوریتمی برای تقسیم مجموعه داده‌ها

گام ۴-۱:

با توجه به اندازه مجموعه داده موجود، درصد متعارفی از مشاهدات باید برای ساخت مدل انتخاب شود. در جریان این مطالعه، این مقدار را P_T می‌نامیم. درصد باقیمانده، برای ارزیابی عملکرد الگوریتم پیشنهادی به کار گرفته می‌شود که P_V نامیده شده است.

گام ششم: نامگذاری نتایج بر مبنای سطوح مختلف اعتماد

نتایج نهایی شبکه عصبی منتخب، امتیاز مشتریان گروه آزمون خواهد بود که بیانگر موقعیت اعتباری آن‌ها است. از آنجایی که متغیر خروجی تعریف شده برای شبکه عصبی فقط شامل دو مقدار ۱ (امتیاز مشتریان بدحساب گروه آموزش) و ۲ (امتیاز مشتریان خوش حساب گروه آموزش) است، به طور منطقی امتیازات اختصاص داده شده به مشتریان گروه آزمون توسط ANN، در بازه ۰.۵ تا ۲.۵ قرار خواهد گرفت. از طرفی، مقادیر اعتماد که در [۲۶] تعریف شده است، در بازه ۱- تا ۵ قرار می‌گیرد. بنابراین برای استفاده از نتایج مقاله [۲۶] در این مطالعه، نیازمند مطابق سازی مقیاس امتیازات اعتباری با مقادیر اعتماد هستیم. از این رو، برای تعیین سطح اعتماد مشتریان، باید حدود جدیدی را جایگزین حدودی که قبلاً برای سطوح مختلف اعتماد تعیین شده بود، بکنیم.

برای این منظور، ابتدا اختلاف بین ماکسیمم امتیاز (MaxC) و مینیمم امتیاز (MinC) محاسبه شده توسط شبکه را به دست می‌آوریم. این متغیر را S می‌نامیم. مقادیر MaxC و MinC، از طریق اجرای شبکه برای گروه‌های مختلف آزمون و مقایسه نتایج آن‌ها حاصل می‌شود. قدم بعدی، محاسبه تفاضل بین ماکسیمم (MaxT) و مینیمم (MinT) مقادیر اعتماد طبق مطالعه [۲۶] است. در ادامه از این متغیر با حرف T یاد می‌شود. با تقسیم مقدار S بر T، میزان اختلاف مورد نظر میان کران بالا و کران پایین بازه‌های جدید برای اعتماد به دست می‌آید. برای محاسبه حدود سطح اول، این مقدار این اختلاف را به مقدار MinC می‌افزاییم. فرمول ۹ به نحوه محاسبه‌ی سطوح جدید اعتماد اشاره دارد:

$$MAPE = \frac{\sum_{i=1}^n \frac{|x_{ANN} - x_{original}|}{x_{original}}}{n} \quad (8)$$

$$B(i) = \text{MinC} + i * \left(\frac{S}{T}\right) \text{ for } i = 0, 1, \dots, T \quad (9)$$

$$T = \text{MaxT} - \text{MinT}$$

$$S = \text{MaxC} - \text{MinC}$$

در جایی که:

$$\text{MaxT} = \text{ماکسیمم مقدار اعتماد اختصاص داده شده به مشتری}$$

$$\text{MinT} = \text{مینیمم مقدار اعتماد اختصاص داده شده به مشتری}$$

$$\text{MaxC} = \text{ماکسیمم امتیاز اعتباری محاسبه شده توسط شبکه}$$

شبکه‌های MLP اغلب از سه لایه نرونی تشکیل شده‌اند؛ لایه ورودی و خروجی که نمایانگر متغیرهای ورودی و خروجی مدل‌اند و در میان آن‌ها یک یا چند لایه مخفی قرار می‌گیرد که توانایی شبکه‌ها را برای یادگیری روابط غیرخطی تأمین می‌کند. در واقع شبکه عصبی در طول فرایند آموزش، روابط بین مؤلفه‌های ورودی و خروجی مجموعه داده را فراگرفته و برای مشاهده‌های موجود در گروه آزمایش، با توجه به مقادیر مؤلفه‌های ورودی آن‌ها، عددی را با عنوان امتیاز اعتباری (خروجی) آن مشاهده ارائه می‌دهد.

در این مرحله، مدل‌های مختلفی اجرا می‌شود که عملکرد آن‌ها با یکدیگر مورد مقایسه قرار خواهند گرفت. تابع انتقال، الگوریتم یادگیری و تعداد نرون‌ها، پارامترهایی هستند که در تعیین معماری شبکه مورد توجه قرار می‌گیرند. در این مطالعه از میان روش‌های یادگیری موجود، از ۹ الگوریتم برای پیدا کردن مناسب‌ترین ANN استفاده می‌شود. همچنین از توابع لگاریتم سیگموئید و تانژانت هایپربولیک سیگموئید به عنوان تابع انتقال یاد می‌شود. بنابراین تا کنون ۱۸ شبکه مختلف برای اجرا کردن در دست داریم (۹ روش آموزشی به همراه دو تابع انتقال). اما از عوامل دیگری که باید در معماری شبکه عصبی مدنظر گرفته شود، تعداد نرون‌ها در لایه یا لایه‌های مخفی است. الگوریتم پیشنهادی هر یک از ۱۸ شبکه مذکور را، برای مقادیر مختلف نرون‌ها (از ۱ تا ۱۰۰) در اولین لایه مخفی آن‌ها، اجرا کرده و آموزش خواهد داد. در مجموع خروجی این بخش، ۱۸۰۰ شبکه متفاوت است.

برای ارزیابی عملکرد شبکه‌ها، میزان دقت آن‌ها را با استفاده از متوسط قدرمطلق درصد خطا^{۲۵} (MAPE) مورد مقایسه قرار می‌دهیم. در زیر به فرمول MAPE اشاره شده است:

برای سهولت در مقایسه مقادیر مختلف MAPE، ۱۸۰۰ شبکه در ۱۸ گروه طبقه‌بندی شده‌اند. هر گروه متشکل از ۱۰۰ شبکه مرتبط با یک الگوریتم یادگیری و تابع انتقال خاصی است که در تعداد نرون‌های موجود در لایه‌های پنهان خود تفاوت دارند. حداقل مقادیر MAPE برای این ۱۸ گروه، محاسبه و با یکدیگر مقایسه می‌شوند. در نهایت، شبکه مربوط به کمترین مقدار MAPE، به عنوان بهترین ANN، انتخاب خواهد شد.


است. این مجموعه فقط شامل مشخصه‌های عددی است. هدف از این مطالعه آن است که با بهره‌گیری از امتیاز اعتباری مشتریان، بتوان سطح قابل اعتماد بودن آنان را تعیین کرد.

گام دوم

با استفاده از فرمول (۱)، داده‌های مزبور نرمالیزه می‌شوند.

گام سوم

برای گزینش مشخصه‌های کلیدی، از ۸۰۰ مشاهده در گروه آموزش و از ۲۰۰ مشاهده برای آزمایش کردن عملکرد ویژگی‌های منتخب استفاده می‌کنیم. در اینجا آزمون t-test را روی هر ویژگی به کار می‌بریم و مقادیر p حاصله هر ویژگی را به عنوان معیار مؤثر بودن آن ویژگی، در تفکیک کردن ریسک اعتباری به دو گروه خوب و بد، در نظر می‌گیریم. سپس نمودار تابع توزیع تجمعی مقادیر P-value را ترسیم می‌کنیم. همان طوری که در شکل (۵) ملاحظه می‌کنید، مقدار p حدود ۴۶ درصد از مشخصه‌ها، نزدیک به صفر و مقادیر p حدود ۶۵ درصد آن‌ها، کمتر از ۰,۰۵ (سطح معنی دار بودن آزمون فرض) دارند؛ به عبارتی حدود ۱۳ ویژگی از بین ۲۰ مشخصه اصلی قدرت تفکیک‌کنندگی بالایی دارند.



شکل ۵: نمودار تابع توزیع تجمعی مقادیر p

پس از پشت سر گذاشتن مرحله پیش‌پردازش و مشخص شدن ۱۳ ویژگی که قدرت تفکیک‌کنندگی بالاتری دارند، وارد فاز سوم، یعنی پیاده‌سازی تکنیک FSFS روی این ویژگی‌ها و تعیین تعداد نهایی مشخصه‌های مورد نیاز برای این مسئله می‌شویم. در حین اجرای الگوریتم FSFS، برای ارزیابی و مقایسه کارایی هر زیر مجموعه کاندید، واری اعتبار ۱۰ الایه‌ای را روی

مینیمم امتیاز اعتباری محاسبه شده توسط شبکه مشروط به اینکه:

اگر $ANN\ output = B(0)$ باشد، آنگاه مشتری، کاملاً غیرقابل اعتماد است؛

اگر $B(0) < ANN\ output \leq B(1)$ باشد، آنگاه مشتری، غیرقابل اعتماد است؛

اگر $B(1) < ANN\ output \leq B(2)$ باشد، آنگاه مشتری، تا حدودی قابل اعتماد است؛

اگر $B(2) < ANN\ output \leq B(3)$ باشد، آنگاه مشتری، به طور عمده قابل اعتماد است؛

اگر $B(3) < ANN\ output \leq B(4)$ باشد، آنگاه مشتری، قابل اعتماد است؛

اگر $B(4) < ANN\ output \leq B(5)$ باشد، آنگاه مشتری، بسیار قابل اعتماد است؛

در واقع به کمک $B(i)$ می‌توان حدود جدید سطوح اعتماد مبتنی بر امتیاز اعتباری مشتریان را به دست آورد. هر یک از قواعد اگر-آنگاه ذکر شده در بالا، به مشتریان با توجه به امتیاز اعتباری‌شان، یک سطح خاص از اعتماد را نسبت می‌دهد. بنابراین پس از تعیین محدوده‌های جدید، مشتریان بر پایه سطح اعتمادشان نامگذاری خواهند شد. بدین ترتیب مدیران تصمیم‌گیرنده می‌توانند به مشتریان خود با توجه به موقعیت اعتمادی آن‌ها، اعطای اعتبار کنند.

پیاده‌سازی مدل اعتبارسنجی مبتنی بر مفهوم اعتماد

در این بخش الگوریتم پیشنهادی را روی یک مجموعه از داده‌های واقعی پیاده می‌کنیم.

گام اول

مجموعه داده استفاده شده در این مطالعه، مربوط به اطلاعات اعتباری مشتریان بانک آلمان است که از بانک داده‌های UCI گرفته شده است [۲۸]. این داده‌ها در برگیرنده اطلاعات مربوط به ۷۰۰ مشتری خوش حساب (با امتیاز ۲) و ۳۰۰ مشتری بد حساب (با امتیاز ۱) است. برای هر متقاضی تسهیلات بانکی، ۲۰ متغیر ورودی برای توصیف سابقه اعتباری، وضعیت حساب‌های بانکی، هدف از درخواست وام، مقدار وام، وضعیت اشتغال، اطلاعات شخصی، سن و وضعیت سکونت وی در نظر گرفته شده

چیدمان متغیرها در این جدول به گونه‌ای است که به متغیرهای با P-value بیشتر (قدرت تفکیک‌کنندگی بالاتر)، رتبه کمتری اختصاص یافته است. در آخر، برای ارزیابی کارایی زیر مجموعه ویژگی‌های انتخاب شده، MCE روی مجموعه آزمایش محاسبه می‌کنیم که برابر با ۰,۲۹ است.

گام چهارم

در این مرحله، داده‌های موجود به دو گروه آموزش که شامل ۹۰ درصد از داده‌ها و مجموعه آزمایش که دربرگیرنده ۱۰ درصد مابقی است، تقسیم می‌شوند. سایر متغیرها به این شرح‌اند:

$$P_V = 10\%, P_T = 90\%$$

تعداد کل مشتریان = ۱۰۰۰

$$R_G = 700/1000 = 70\%, R_B = 300/1000 = 30\%$$

تعداد خوش حساب‌ها برای مجموعه آموزش =

$$630 = (0,7) * (0,9) * (1000)$$

تعداد بدحساب‌ها برای مجموعه آموزش =

$$270 = (0,3) * (0,9) * (1000)$$


تعداد خوش حساب‌ها برای مجموعه ارزیابی =

$$70 = (0,7) * (0,1) * (1000)$$

تعداد بدحساب‌ها برای مجموعه ارزیابی =

$$30 = (0,3) * (0,1) * (1000)$$

مجموعه آموزشی به کار می‌بریم. سپس نمودار خطای طبقه‌بندی نادرست (CVMCE) را برای ویژگی‌ها رسم می‌کنیم (شکل ۶). همان طور که در شکل مشاهده می‌کنید، با انتخاب ۸ ویژگی نمودار به مقدار مینیمم محلی خود می‌رسد و سپس از ویژگی ۸ تا ۱۰ تغییر قابل ملاحظه‌ای نمی‌کند. زمانی که الگوریتم بیش از ۱۱ ویژگی را به کار می‌گیرد، مقدار نمودار افزایش می‌یابد. طبق [۱۲]، هر چه تعداد متغیرهای ورودی به مسئله (مشخصه‌ها) کمتر باشد، مدل طبقه‌بندی‌کننده از قدرت پیش‌بینی بیشتری بهره‌مند است و محاسبات کمتری نیاز دارد. بنابراین، در نهایت نخستین ۸ مشخصه منتخب توسط الگوریتم FSFS به عنوان ویژگی‌های کلیدی برای این مسئله انتخاب می‌شوند. لیستی از مشخصه‌های نهایی گزینش شده در جدول (۲) ارائه شده است.



شکل ۶: نمودار خطای طبقه‌بندی نادرست با استفاده از واریسی اعتبار ۱۰ لایه‌ای

جدول ۱: معرفی مشخصه‌های نهایی گزینش شده

Rank	Variable	Description
1	Duration	Duration in month
2	Employment	State 1 : unemployed; State 2 : x < 1 year; State 3 : 1 ≤ x < 4 years; State 4 : 4 ≤ x < 7 years; State 5 : x ≥ 7 years
3	Credit history	State 1: no credits taken; State 2: all credits paid back duly; State 3: existing credit paid back duly till now; State 4: delay in paying off in the past; State 5: critical account
4	Credit amount	The amount of requested credit
5	Checking status	State 1: x < 0 DM; State 2: 0 ≤ x < 200 DM; state 3: x ≥ 200 DM/ salary assignment for at least 1 year; state 4: no checking account.
6	Saving status	State 1 : x < 100 DM; State 2: 100 ≤ x < 500 DM; State 3: 500 ≤ x < 1000 DM; State 4 : x ≥ 1000 DM; State 5: unknown/ no savings account
7	Property Magnitude	State 1 : real estate; State 2 : if not State 1 : building society savings agreement/life insurance; State 3 : if not State 1/ State 2 : car or other; State 4 : unknown / no property
8	Installment commitment	Installment rate in percentage of disposable income

جدول ۲: ساختار شبکه‌ها و کمترین MAPE در گروه‌ها

MLP Model Number	Learning Method	Number of neurons in hidden layer	Transfer Function	MAPE
1	LM	64,76,93	Log-sigmoid	0.18
2	SCG	35,89	Log-sigmoid	0.175
3	RP	1	Log-sigmoid	0.175
4	OSS	4	Log-sigmoid	0.16
5	GDX	74	Log-sigmoid	0.19
6	GDA	12	Log-sigmoid	0.185
7	CGB	67	Log-sigmoid	0.155
8	BR	37,58	Log-sigmoid	0.17
9	BFG	5	Log-sigmoid	0.165
10	LM	15	Tan-sigmoid	0.15
11	SCG	45	Tan-sigmoid	0.17
12	RP	2	Tan-sigmoid	0.16
13	OSS	31	Tan-sigmoid	0.165
14	GDX	23	Tan-sigmoid	0.165
15	GDA	15,77	Tan-sigmoid	0.185
16	CGB	61	Tan-sigmoid	0.165
17	BR	31,47	Tan-sigmoid	0.17
18	BFG	2	Tan-sigmoid	0.16

جدول ۴: معرفی سطوح اعتماد مبتنی بر امتیاز اعتباری

Trust-based Score Scale	Semantics of Trust Level	Credit Score Value
Level 0	Very Weak (VW)	$x = 1.13$
Level 1	Weak (W)	$1.13 < x \leq 1.33$
Level 2	Medium (M)	$1.33 < x \leq 1.53$
Level 3	Medium High (MH)	$1.53 < x \leq 1.73$
Level 4	High (H)	$1.73 < x \leq 1.93$
Level 5	Very High (VH)	$1.93 < x \leq 2.13$

جدول ۵: نتایج گروه تست به تفکیک سطوح اعتماد

	Very High	High	Medium High	Medium	Other
GOOD	18	29	9	4	8
PERCENTAGE	26.5	42.6	13.2	5.9	11.8
	Very Weak	Weak	Medium	Medium High	Other
BAD	0	8	14	4	6
PERCENTAGE	0	25	43.8	12.5	18.8

گام پنجم

بنابراین، MinT برابر با صفر خواهد بود و در نتیجه مدل پیشنهادی از ۶ سطح تشکیل می‌شود:

$$\text{MaxT} = 5, \text{MinT} = 0, \text{MaxC} = 2.12, \text{MinC} = 1.13, \\ T = 5 - 0 = 5, S = 2.12 - 1.13 = 0.99 \approx 1$$

$$B(i) = 1.13 + i * \left(\frac{1}{5}\right) \quad \text{for } i = 0, 1, \dots, 5$$

$$\begin{aligned} B(0) &= 1.13 \\ B(1) &= 1.13 + (1)(0.2) = 1.33 \\ B(2) &= 1.13 + (2)(0.2) = 1.53 \\ B(3) &= 1.13 + (3)(0.2) = 1.73 \\ B(4) &= 1.13 + (4)(0.2) = 1.93 \\ B(5) &= 1.13 + (5)(0.2) = 2.13 \end{aligned}$$

توضیحات مربوط به هر سطح در جدول (۴) ارائه شده است.

برای آخرین مرحله که نامگذاری مشتریان بر مبنای سطوح مختلف اعتماد است، ۳ گروه آزمایش متشکل از اطلاعات مربوط به ۶۸ مشتری خوش حساب و ۳۲ مشتری بدحساب را انتخاب می‌کنیم. با در نظر گرفتن بازه‌های تعیین شده در جدول (۴)، این مشتریان را در سطوح مختلف اعتماد طبقه‌بندی می‌کنیم.

پس از پیاده‌سازی این مدل، آن تعداد از مشتریانی که توسط شبکه، لقب خوش حساب به آن‌ها اطلاق شده بود، با گروه‌های بیشتری تفکیک شده‌اند. برای بررسی بهتر نتایج، درصد مشتریان خوش حساب واقعی را که هر یک طبق سطح اعتمادشان در هر یک از گروه‌های خیلی قوی، قوی، متوسط بالا و یا متوسط قرار گرفته‌اند، محاسبه می‌کنیم. همچنین درصد مشتریان واقعا بدحساب که با عنوان هر یک از گروه‌های خیلی ضعیف، ضعیف، متوسط و یا متوسط بالا دسته‌بندی شده‌اند را نیز محاسبه می‌کنیم. در جدول (۵) نتایج حاصله برای یکی از گروه‌های آزمایش ارائه شده است.

در جدول (۵) مشاهده می‌کنیم که حدود ۲۶٫۵٪ از مشتریان واقعا خوش حساب، جزو گروه بسیار قوی از نظر سطح اعتماد قرار گرفته‌اند. در این گونه موارد، مدیران تصمیم‌گیرنده می‌توانند سیاست‌های تشویقی برای مشتریان اعمال کنند. از آنجایی که این گروه، نمره اعتماد بالایی دارند، اطلاعات ارائه‌شده توسط آن‌ها قابل اطمینان بوده و انجام معامله با آن‌ها منجر به کسب سود برای مؤسسه مالی خواهد شد. در واقع سیاست یک بانک مشتری‌مدار، باید بر پایه حفظ رضایتمندی این گروه از مشتریان بنا شود.

همه مدل‌های شبکه عصبی تعیین شده را اجرا کرده، عملکرد آنها را روی گروه آزمون می‌سنجیم. سپس کارایی هر مدل را با استفاده از MAPE ارزیابی می‌کنیم. نتایج حاصل از ۱۸۰۰ شبکه را در ۱۸ گروه دسته‌بندی می‌کنیم. در جدول ۳-۴، ساختار هر یک از این ۱۸ گروه و حداقل میزان MAPE در هر گروه نشان داده شده است. همچنین به تعداد نرون‌ها در لایه مخفی شبکه‌ای که در هر گروه کمترین میزان MAPE را دارد نیز اشاره شده است.

پس از بررسی ساختار شبکه‌ها در جدول (۳)، کمترین میزان MAPE (برابر با ۱۵ درصد)، مربوط به حالتی است که از Levenberg-Marquardt back propagation به عنوان الگوریتم یادگیری و از تانژانت هایدربولیک سیگموئید به عنوان اولین تابع انتقال استفاده شده و ۱۵ نرون نیز در لایه مخفی قرار گیرد. در این مدل مقدار خطای نوع اول ۱۳٪ و خطای نوع دوم ۳۰٪ است که در مقایسه با میزان خطاهای ذکر شده در مقاله [۵] مقدار قابل قبولی است. از طرف دیگر، نرخ طبقه‌بندی درست با استفاده از این الگوریتم، ۷۸٫۵٪ است که در مقایسه با مقدار ذکر شده در [۲۲، ۹، ۴]، نرخ نرمالی محسوب می‌شود (لازم به ذکر است در همه مدل‌های یادشده در مقالات ذکر شده، از شبکه عصبی و مجموعه داده مربوط به اطلاعات اعتباری مشتریان بانک آلمان بهره گرفته شده است).

گام ششم

در این مرحله، از فرمول ۹ برای تعیین حدود جدید اعتماد استفاده می‌کنیم. در این راستا، لازم است تا کمترین و بیشترین امتیاز اعتباری نسبت داده شده به مشتریان معین شود. برای دستیابی به این هدف، شبکه عصبی منتخب را برای ۲۰ گروه آزمایش متفاوت اجرا می‌کنیم و نتایج را برای تعیین بیشترین و کمترین امتیاز، بررسی می‌کنیم.

نکته‌ای که در اینجا باید به آن اشاره کرد آن است که سطح اعتماد (۱-)، در زمینه اعتبارسنجی کاربرد چندانی ندارد. شبکه به هر یک از مشتریان جدید، با توجه به اطلاعات برگرفته از فرم درخواستشان، یک امتیاز اعتباری نسبت می‌دهد. بنابراین، موقعیت این مشتریان نیز تخمین زده می‌شود و برای وام‌دهنده نامعلوم باقی نمی‌ماند.

ایجاد محدودیت در مقدار وام، می‌تواند این مشتریان را به سمت بهتر عمل کردن در زمینه مسئولیت‌های مالی شان سوق دهد.

گروه بسیار ضعیف یا کمترین نمره، مشمول حال مشتریانی می‌شود که با هیچ شرایطی قابل اعتماد نیستند. پرونده مالی آن‌ها همواره مملو از گزارش‌های تأخیر یا عدم پرداخت وام‌های دریافت‌شده توسط آن‌ها است. در واقع عقد معامله با این گروه از مشتریان، زیان مسلم است. بنابراین رد کردن فرم درخواست وام این دسته از مشتریان، برای مدیران به صرفه خواهد بود.

آخرین ستون جدول (۵)، سایر نامیده شده است که نمایانگر درصد خطای شبکه در گروه‌بندی مشتریان است. واضح است که هر چه این ستون شامل اعداد کوچک‌تری باشد، شبکه از مطلوبیت بیشتری بهره‌مند خواهد بود.

نتیجه‌گیری

در این مطالعه برای اولین بار الگوریتمی بر پایه اعتماد در راستای اعتبارسنجی مشتریان بانکی ارائه شده است. مدل پیشنهادی از قابلیت پیش‌بینی وضعیت اعتباری مشتریان با توجه به سطوح اعتماد آنان برخوردار است. با توجه به کاربرد اخیر مدل‌های اعتبارسنجی در عرصه تجارت آنلاین و اهمیت ویژه مفهوم اعتماد در شکل‌گیری معاملات الکترونیکی، الگوریتم مذکور در این راستا بسیار کارآمد خواهد بود. از طرف دیگر، با پیاده‌سازی چنین مدلی وام‌دهندگان قادر خواهند بود تا از طریق شناخت شدت خوش‌حسابی/بدحسابی مشتریان، سیاست‌های ویژه‌ای را در راستای واگذاری اعتبار به آنان اعمال کنند.

در این مدل پس از آماده‌سازی داده‌ها، از طریق اعمال روش فیلتر و Wrapper، مشخصه‌های کلیدی مجموعه داده‌ها تعیین می‌شوند. سپس، بهترین ساختار شبکه عصبی برای تخمین امتیاز اعتباری مشتریان تعیین می‌شود. در نهایت مشتریان با توجه به نمره اعتباری خود، در یکی از ۶ سطح تعریف شده برای اعتماد، گروه‌بندی خواهند شد.

۴۲٫۶٪ از گروه خوش‌حساب، با عنوان مشتریانی با سطح اعتماد قوی برچسب زده شده‌اند. برای مشتریان این زیرمجموعه، بانک می‌تواند از سیاست‌های انگیزشی بهره‌بردار تا آنان را به سمت بالا بردن نمره اعتمادشان تا سطح قوی برانگیزد. ارائه بازخورد سالانه از بهبود در امتیاز مشتریان، می‌تواند در این زمینه مثر ثمر واقع شود.

گروه بعدی، متوسط بالا، را همچنین می‌توان به عنوان یک گروه مرزی نامید. مشتریان این گروه را می‌توان هم جزو مشتریان خوش‌حساب به شمار آورد و هم در زمره مشتریان بدحساب محسوب کرد. برای توضیح بیشتر می‌توان به درصدهای تقریباً یکسان در دسته متوسط بالا، در هر دو قسمت جدول (۵) (مشتریان

خوش‌حساب و مشتریان بدحساب) اشاره کرد. البته مدیران می‌توانند با اعمال سیاست‌های تشویقی درست و به موقع، این مشتریان را به سمت بهبود بخشیدن به وضعیتشان ترغیب کنند. بهتر است تا همواره مزایای مختلف مشتریان دو گروه قوی و بسیار قوی را به این دسته یادآور شویم.

مشتریان گروه متوسط، تاحدی غیرقابل اعتماد محسوب می‌شوند. اطلاعات ارائه‌شده توسط آنان همیشه قابل اطمینان نیستند. در برهه‌های زمانی متفاوت، این دسته از مشتریان اغلب جزو گروه بدحساب گمارده می‌شوند، اما در برخی موارد هم همچون مشتریان خوش‌حساب عمل می‌کنیم. پیاده‌سازی سیاست‌های اخطارگونه برای این گروه، ممکن است منجر به وادار کردن آنها در بهبود بخشیدن به وضعیت خود شود. چنانچه این مشتریان از شرایط و محدودیت‌های مشتریان گروه ضعیف مطلع شوند، ممکن است برای افزایش نمره خود تلاش کنند.

بانک‌ها و مؤسسه‌های مالی نمی‌توانند به مشتریان گروه ضعیف اعتماد کنند. عدم ثبات وضعیت مالی این مشتریان، امکان ایجاد ضرر برای مؤسسه را به دنبال دارد. استفاده از سیاست‌های جریمه‌ای مانند افزایش نرخ سود یا

مراجع

- 1- Yu, L., Wang, S., Lai, K. K. and Zhou, L. (2008). *Bio-Inspired Credit Risk Analysis: Computational Intelligence with Support Vector Machines*, Springer.
- 2- Eskandari, S. (2006). "A Model for Customer Credit Scoring in Financial Market for Avoiding Ill- Credit Decision." MSc, School of Social & Economic Science, Alzahra University, Tehran.

- 3- Bellotti, T. and Crook, J. (2009). "Support vector machines for credit scoring and discovery of significant features." *Expert Systems with Applications*, 36, 3302.
- 4- Abdou, H., Pointon, J. and El-Marsy, A. (2008). "Neural nets versus conventional techniques in credit scoring in Egyptian banking." *Expert Systems with Applications*, 35, 1277-1279.
- 5- Lee, T. and Chen, I. (2005). "A two-stage hybrid credit scoring model using artificial neural networks and multivariate adaptive regression splines." *Expert Systems with Applications*, 28(4), 743-752.
- 6- Zekic-Susac, M., Sarlija, N. and Bensic, M. (2004). "Small Business Credit Scoring: A Comparison of Logistic Regression, Neural Networks, and Decision Tree Models." *26th International Conference on Information Technology Interfaces*. Croatia.
- 7- Yang, Y. (2007). "Adaptive credit scoring with kernel learning methods." *European Journal of Operational Research*, 183.
- 8- Leondes, C. T. (2005). "Intelligent Knowledge-Based Systems: Business and Technology in the New Millennium." Kluwer Academic Publishers.
- 9- Ong, C., Huang, J. and Tzeng, G. (2005). "Building credit scoring models using genetic programming." *Expert Systems with Applications*, 29(1), 41-47.
- 10- Zhang, G. P. (2003). "Neural Networks in Business Forecasting." *Information Science Publishing*.
- 11- Chuang, C. and Lin, R. (2009). "Constructing a reassigning credit scoring model." *Expert Systems with Applications*, 36, 1685-1687.
- 12- Huang, C. L., Chen, M. C. and Wang, C. J. (2007). "Credit scoring with a data mining approach based on support vector machine." *Expert Systems with Applications*, 33(2007).
- 13- Chen, M. and Huang, S. (2003). "Credit scoring and rejected instances reassigning through evolutionary computation technique." *Expert Systems with Applications*, 24(2003), 433-434.
- 14- Bocij, P., Chaffey, D., Greasley, A. and Hickie, S. (2009). "Business Information Systems: Technology, Development & Management for the E-business." FT Press.
- 15- Islam, S., Zhou, L. and Li, F. (2009). "Application of Artificial Intelligence (Artificial Neural Network) to Assess Credit Risk: A Predictive Model For Credit Card Scoring." MSc, School of Management Blekinge Institute of Technology.
- 16- Bargharar, M. (2006). "A New Model For Credit Rating Using Fuzzy Logic." MSc, School of Economic, Shiraz University.
- 17- Tsai, C. and Wu, J. (2008). "Using neural network ensembles for bankruptcy prediction and credit scoring." *Expert Systems with Applications*, 34, 2639-2640.
- 18- Liang, Q. (2003). "Corporate financial distress diagnosis in China: Empirical analysis using credit scoring models." *Hitotsubashi Journal of Commerce and Management*, 38(1), 13-28.
- 19- Malhotra, R., and Malhotra, D. K. (2003). "Evaluating consumer loans using neural networks." *Omega the International Journal of Management Science*, 31(2), 83-96.
- 20- Seow, H. and Thomas, L. C. (2006). "Using adaptive learning in credit scoring to estimate take-up probability distribution." *European Journal of Operational Research*, 173(3), 880-892.
- 21- Zekavat, M. (2003). "The Credit Risk Models for Customers of Tose'ey Saderat Bank." MSc, College of banking, Tehran.

- 22- Mirzaee, A. (2007). "A Hybrid Analytic Model for banking industry Using Artificial Intelligence." MSc, School of Human Science, Tarbiat Modares University, Tehran.
- 23- Corritore, C., Kracher, B. and Wiedenbeck, S. (2003). "Online trust: Concepts, evolving themes, a model." *Int. J. Human-Computer Studies*, 58,737-738.
- 24-Hussain, F. K., Chang, E. and Dillon, T. (2004). "Classification of trust in Peer-to-Peer (P2P) communication." *International journal of Engineering Intelligent Systems*.
- 25-Hussain, F. K., Chang, E. and Dillon, T. (2004). "Trustworthiness and CCCI metrics in P2P communication." *International journal of Computer Systems Science & Engineering*.
- 26-Hussain, F. K., Chang, E. and Dillon, T. (2006). *Trust and reputation for service-oriented environments*. Vol.1: Technologies for building business intelligence and consumer confidence. West Sussex, England: John Wiley and Sons.
- 27-Azadeh, A., Saberi, M. and Anvari, M. (2010). "An integrated artificial neural network algorithm for performance assessment and optimization of decision making units." *Expert Systems with Applications*, 37, 5690.
- 28-Frank, A. and Asuncion, A. (2010). UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science.

واژه‌های انگلیسی به ترتیب استفاده در متن

- 1- Fisher
- 2- Dunham
- 3- Durand
- 4- Logistic Regressions (LR)
- 5- Discriminant Analysis (DA)
- 6- K-Nearest Neighbour (KNN)
- 7- Probit Analysis (PA)
- 8- Classification And Regression Tree (CART)
- 9- Multivariate Adaptive Regression Splines (MARS)
- 10- Artificial Neural Network (ANN)
- 11- Genetic Algorithm (GA)
- 12- Support Vector Mashine (SVM)
- 13- Back-Propagation
- 14- Feed-Forward
- 15- Reputation
- 16- Trusting Agent
- 17- Trusted Agent
- 18- Cumulative Distribution Function
- 19- Forward Sequential Feature Selection
- 20- MisClassification Error
- 21- Quadratic Discriminant Analysis
- 22- 10-fold Cross-Validation
- 23- Cross-Validation MisClassification Error
- 24- Multi-Layer Perceptron
- 25- Mean Absolute Percentage Error