



## بررسی ریسک اعتباری مشتریان با استفاده از شبکه عصبی مصنوعی

سحر عباسپور، کارشناس ارشد توسعه اقتصادی و برنامه ریزی،

[saharabaspur@gmail.com](mailto:saharabaspur@gmail.com)

مینو نظیفی نایینی، کارشناس ارشد توسعه اقتصادی و برنامه ریزی

[minoonzifi@gmail.com](mailto:minoonzifi@gmail.com)

### چکیده

رتبه بندی اعتباری یکی از موضوعات مهمی است که همواره مورد توجه بانکداران قرار می گیرد. به منظور مدیریت و کنترل ریسک اعتباری، سیستم های رتبه بندی اعتباری مشتریان ضرورتی انکار ناپذیر دارد. همچنین اهمیت اعطای تسهیلات در صنعت بانکداری کشور و نقش خطیر آن در رشد اقتصادی و افزایش اشتغال منجر به توسعه چندین مدل گوناگون برای ارزیابی اعتباری مشتریان متقاضی این تسهیلات شده است. رتبه بندی اعتباری به منظور پیش بینی احتمال کوتاهی در باز پرداخت و یا عدم باز پرداخت و یا معادل آن برای طبقه بندی متقاضیان اعتبار به دو گروه ریسک خوب و ریسک بد مورد استفاده قرار می گیرد. از جمله مزایای این روش می توان به صرفه جویی در زمان، صرفه جویی در هزینه، حذف قضاوت های شخصی و افزایش دقت در ارزیابی متقاضیان وام اشاره کرد. روش های آماری مختلفی از جمله آنالیز ممیزی، رگرسیون لجستیک، روش های هموارسازی ناپارامتری و شبکه های عصبی در زمینه رتبه بندی اعتباری مورد استفاده قرار گرفته اند. بسیاری از این مدل ها، مدل های کلاسیک هستند و توانایی ارزیابی

اعتباری مشتریان را بطور کامل و بهینه ندارند. بنابراین زمینه ورود مدل‌های هوش مصنوعی به این حوزه مهیا گردیده است. شبکه‌های عصبی به دلیل انعطاف‌پذیری بالاتر، در سال‌های اخیر بیشتر مورد توجه قرار گرفته‌اند. در این مقاله، به توضیح مدل شبکه عصبی مصنوعی برای اعتبار دهی مشتریان و طبقه‌بندی متقاضیان دریافت وام با استفاده از نرم‌افزار SPSS و معرفی قابلیت‌های این نرم‌افزار در رتبه‌بندی اعتبار دهی مشتریان پرداخته شده است. با استفاده از ROC curve بوسیله دو معیار حساسیت و تصریح، الگوی مناسب برای طبقه‌بندی ریسک‌های خوب و بد اعتباردهی برای پیش‌بینی خوش‌اعتباری و بد‌اعتباری مشتریان ارائه می‌دهد و کارایی و دقت مدل شبکه عصبی مصنوعی را در رتبه‌بندی اعتباری بررسی خواهیم کرد.

کلمات کلیدی: رتبه‌بندی اعتباری، مدل رتبه‌بندی، شبکه عصبی، پرسپترون چندلایه، ROC curve

## مقدمه

توسعه و گسترش فعالیت‌های بانکی با سیستمی کارآمد در پیشرفت و توسعه اقتصاد کشور بسیار مؤثر خواهد بود و باعث دوام بانک در محیط رقابتی خواهد گردید. بانکها هنگامی می‌توانند این منابع خود را به صورت بهینه و کارآمد به مشتریان تخصیص دهند که از سیستم قابل‌ارزشگذاری و رتبه‌بندی مشتریان خود در هنگام اعطای تسهیلات برخوردار باشند.

صنعت اعتبار امروزه نقش مهمی در اقتصاد کشورها یافته است. با افزایش تقاضای اعتبار و افزایش رقابت، فرصت‌های جدید برای موسسات اعتبار دهنده بوجود آمده است و نیاز آنها را به ابزارها و روش‌های نوین افزایش می‌دهد.

در صنعت بانکداری یکی از موضوعات مهمی که همواره مورد توجه سیاست‌گذاران اعتباری قرار دارد، بحث مدیریت ریسک اعتباری است. به منظور مدیریت و کنترل ریسک مذکور، سیستم‌های رتبه‌بندی اعتباری مشتریان ضرورتی انکارناپذیر است. چنین سیستمی، بر اساس سوابق و اطلاعات موجود، درجه اعتبار مشتریان را تعیین و آنان را بر اساس میزان ریسکی که متوجه بانک خواهند کرد، رتبه‌بندی می‌کند. بهره‌گیری از چنین سیستمی بانک را در گزینش مطلوب مشتریان خود یاری کرده و ضمن کنترل و کاهش ریسک اعتباری، سطح بهره‌وری فرآیند اعطای تسهیلات بانکی را ارتقا می‌دهد.

با وجود اهمیت این موضوع، در اقتصاد ایران، در زمینه اعطای تسهیلات اعتباری به مشتریان، روند منسجم و منظمی به منظور تعیین ریسک اعتباری، امتیازدهی، درجه‌بندی و همچنین تعیین سقف‌های اعتباری بر اساس شاخص‌های ریسک ملاحظه نمی‌شود و شاخص‌ها بیشتر بر اساس تشخیص کارشناسی و کمیته اعتباری صورت می‌گیرد. روش‌های آماری مختلفی در زمینه رتبه‌بندی اعتباری مورد استفاده قرار گرفته‌اند. این مدل‌های آماری را علاوه بر مدل‌های رتبه‌بندی، طبقه‌بندی‌کننده و یا کارت امتیاز نیز می‌نامند.

از این مدل‌ها برای پیش‌بینی احتمال کوتاهی و یا عدم بازپرداخت وام توسط افراد متقاضی و با دریافت‌کننده وام استفاده می‌شود.

در مطالعات گذشته نیز بیشتر از روش‌های آماری مانند مدل‌های رگرسیونی و روش تحلیل ممیزی برای امتیازدهی و رتبه‌بندی مشتریان استفاده می‌شد، ولی در سال‌های اخیر با توسعه مدل‌های مبتنی بر هوش مصنوعی و روش‌های ابتکاری، مطالعات بسیاری در کاربرد این روش‌ها در مدل‌های امتیازدهی و رتبه‌بندی اعتباری انجام گرفته است.

از زمانی که سیستم‌های هوش مصنوعی نظیر شبکه‌های عصبی مصنوعی، الگوریتم‌های ژنتیک و سیستم‌های خبره<sup>۱</sup> طراحی و معرفی شده‌اند، استفاده از آنها در تحقیقات مالی و رتبه‌بندی اعتباری مرسوم گشته و به سرعت در حال گسترش و نوآوری است. در این مقاله به معرفی مدل‌های شبکه عصبی در رتبه‌بندی اعتباری متقاضیان وام پرداخته شده است و مدل اصلی استفاده شده برای طبقه‌بندی، یک مدل شبکه عصبی پرسپترون چندلایه با الگوریتم یادگیری پس انتشار خطاست.

## ۱- رتبه‌بندی و مدل‌های آن

هدف رتبه‌بندی اعلام کیفیت یک وام‌گیرنده و دورنمای بازپرداخت آن به بازار است. رتبه‌ها این قابلیت را دارند که برای مشاهده گران خارجی مثل مقامات نظارتی و شرکت‌کنندگان در بازار نسبت به یک شرکت در بازار اعتبار ایجاد نمایند. البته اعتبار اطلاعات رتبه‌بندی ارتباط نزدیکی با مقررات قابل قبول رتبه‌بندی دارد. طبقات رتبه‌بندی شکل مختصر شده خطر اعتباری هستند. رتبه‌ها می‌توانند بر اساس اطلاعات گذشته به تواتر نسبی نکول مرتبط باشند یا می‌توانند مبنایی برای ارزش‌گذاری یک دارایی محسوب گردند. شاخص‌ترین تقاضا برای رتبه‌ها در بخش مدیریت دارایی بدهی شرکتی، زمانی است که بازده‌های سرمایه تعدیل شده بر حسب ریسک، معیار پایه برای ارزیابی عملکرد بخشی تلقی می‌شوند. رتبه‌ها برای بانک این امکان را فراهم می‌کنند که خطر اعتباری را اندازه‌گیری نموده و آن را متناسب با پرتفوی اعتباری اداره کنند و مفهوم اکسپوژر بانک را در رابطه با انواع خطر تعدیل و اصلاح نمایند. رتبه‌ها، مخصوصاً برای ارزش‌گذاری یک اوراق قرضه و یا یک وام مفید هستند و رابطه‌ای مثبت ویژه بین خطر اعتباری مورد انتظار و بازده اسمی را بیان می‌کنند. دلایل مذکور در فوق در مجموع بیانگر علت توجه طیف گسترده‌ای به کیفیت سیستم رتبه‌بندی یک موسسه مالی است. روش‌های متفاوتی وجود دارند که از طریق آنها می‌توان یک رتبه بدست آورد. از آن جمله می‌توان به اندازه‌گیری احتمال وقوع نکول اشاره کرد. روش مشخصی که امروزه کاربرد دارد، روش امتیازدهی است. این روش متکی به مجموعه‌ای از معیارهاست که هر یک به خوبی تعریف شده‌اند. به هر یک از معیارها بطور جداگانه امتیاز داده می‌شود. به

هر امتیاز که به مجموعه ای از معیارها مرتبط است وزنی داده می شود، سپس اینها با هم جمع می شوند. حاصل جمع، یک امتیاز کلی است. این امتیاز به یکی از طبقات رتبه تبدیل می گردد که در حد فاصل بین حداقل امتیاز کلی تا حداکثر آن قرار می گیرد. شبکه های عصبی مصنوعی، جزو آن دسته از سیستم های دینامیکی قرار دارند که با پردازش روی داده های تجربی، دانش یا قانون نهفته در ورای داده ها را به ساختار شبکه منتقل می کنند. به همین خاطر به این سیستم ها هوشمند می گویند چرا که بر اساس محاسبات روی داده های عددی یا مثالها، قوانین کلی را فرا می گیرند. این سیستمهای مبتنی بر هوش محاسباتی سعی در مدلسازی ساختار نوروسیناپتیکی مغز بشر دارند. کاربردهای شبکه های عصبی در حوزه مالی پیشرفت چشم گیری داشته است. حیطه هایی که شبکه های عصبی در امور مالی می توانند کارایی داشته باشند، شامل شبیه سازی مالی، پیش بینی رفتار سرمایه گذارها، ارزیابی اهداف، ارزیابی اعتبار، مدیریت پورتفوی دارایی قیمت گذاری اولیه اوراق قرضه، تعیین ساختار سرمایه بهینه و پیش بینی مالی می باشد.

فرایند تایید بر اساس امتیازبندی اعتبار را می توان توسط نرم افزار و تجهیزات کامپیوتری معمولی به طور موفقیت آمیزی انجام داد. هر چند که چنین سیستم هایی نمی توانند در عملیات خود المانهای کیفی، ذهنی فرایند تصمیم گیری انسان را لحاظ کنند. بعلاوه، اکثر اطلاعات مربوط به مشتریان در فرمت استاندارد به دست تصمیم گیرنده نمی رسد. هر چند که امروزه در غالب بانکهای تجاری جهان و همچنین در کلیه بانکهای تجاری کشور اغلب از روش قضاوتی برای تعیین ریسک و ظرفیت اعتباری مشتریان استفاده می شود؛ لیکن استفاده از این روش با توجه به توان محدود انسان در تحلیل هم زمان فاکتورهای مختلف موثر بر ریسک و ظرفیت اعتباری دریافت کنندگان اعتبار روش قضاوتی در مقایسه با روش های آماری و همچنین روش های هوش مصنوعی از کارایی کمتری برخوردار است.

## ۲- مطالعات انجام شده

در مورد کاربرد شبکه های عصبی در رتبه بندی اعتباری، مقالات متعددی وجود دارد. وست<sup>۱</sup> به مقایسه دقت طبقه بندی پنج مدل شبکه عصبی MLP<sup>۲</sup>، RBF<sup>۳</sup>، LVQ<sup>۴</sup>، FAR<sup>۵</sup>، MOE<sup>۶</sup> و چهار مدل آماری رگرسیون لجستیک، نزدیک ترین همسایگی ها، آنالیز ممیزی و چگالی کرنل پرداخته است. در این میان مدل های MOE، RBF، MLP به عنوان مدل های برتر انتخاب شده اند.

جنسون در سال ۱۹۹۲ از شبکه عصبی برای امتیازدهی اعتبار استفاده نمود. دقت این شبکه بین ۷۶ تا ۸۰ درصد بود. اگر چه اندازه نمونه جنسون بسیار کوچک بود و تنها ۱۲۵ متقاضی وام را شامل می شد. دزای و

1 West,2000

2 Multi Layer Perceptron

3 Radial Basis Function

4 Learning Vector Quantization

5 Fuzzy Adaptive Resonance

6 Mixture of Experts

همکاران در سال ۱۹۹۷ به مقایسه شبکه های عصبی، تحلیل تمایز خطی و رگرسیون لجستیک پرداختند. آنها در مطالعاتشان به این نتیجه رسیدند که در طبقه بندی متقاضیان وام به مشتریان خوش اعتبار و بد اعتبار شبکه های عصبی از تحلیل تمایز خطی بهتر عمل می کند و نسبتاً عملکرد مشابهی نسبت به رگرسیون لجستیک دارند.

در سال ۲۰۰۶ ترینکل<sup>۱</sup> در پایان نامه دکترای خود به مقایسه قدرت شبکه عصبی مصنوعی و مدل های آماری سنتی در امتیازدهی اعتباری پرداخت. وی دو فرضیه داشت: اول اینکه قدرت طبقه بندی شبکه های عصبی از روش های آماری سنتی بیشتر است و دوم اینکه با تغییر تکنیک های تفسیر وزن های شبکه عصبی، امتیازدهی اعتبار نتایج متفاوتی خواهد داشت. نتایج پژوهش وی دو فرضیه فوق را اثبات نمود.

مالهترا و مالهترا<sup>۲</sup> از یک مدل شبکه عصبی پرسپترون چندلایه برای طبقه بندی مشتریان ۱۲ موسسه مالی در آمریکا استفاده و نتایج آن را با روش آنالیز ممیزی مقایسه کردند که باز هم مدل شبکه عصبی دقت طبقه بندی بالاتری را نشان داد.

کیم و سون<sup>۳</sup> در مقاله خود از یک روش شبکه عصبی برای طبقه بندی متقاضیان وام استفاده کردند. در نهایت، مدل، دقت کلی معادل ۷۱-۸۴ درصد در داده های فراگیری و ۶۹-۸۴ درصد در داده های آزمایشی به دست آورد.

در ایران نیز مقالات متعددی در زمینه کاربردهای شبکه عصبی در زمینه های مختلف از جمله پزشکی، مهندسی و اقتصاد به چاپ رسیده است. اما کاربرد شبکه عصبی در رتبه بندی اعتباری کمتر مورد توجه قرار گرفته است. اخباری و مخاطب رفیعی (۱۳۸۹) در مقاله ای با عنوان کاربرد سیستم های استدلال عصبی - فازی در رتبه بندی اعتباری مشتریان حقوقی بانک ها مدل رتبه بندی اعتباری با استفاده از سیستم استدلال عصبی - فازی جهت رتبه بندی مشتریان حقوقی بانکها ارائه داده اند. نتایج مطالعه آنها پس از آموزش و تست مدل بر اساس داده های بانک کشاورزی طی سال های ۱۳۸۵-۱۳۸۰، مدل ارائه شده با دقت ۶۹.۳۶ درصد وضعیت اعتباری مشتریان را پیش بینی می کند.

رجب زاده و همکاران (۱۳۸۸) در مطالعه ای با عنوان طراحی سیستم هوشمند ترکیبی رتبه بندی اعتباری مشتریان بانک ها با استفاده از مدل های استدلالی فازی ترکیبی، نتایج سیستم هیبریدی و هیبریدی فازی سیستم را با نتایج سیستم خبره مقایسه کردند، نتایج حاکی از دقت و قدرت بالای سیستم هوشمند هیبریدی نسبت به سیستم خبره در رتبه بندی اعتباری مشتریان است. نیلساز و همکاران (۱۳۸۶) به بررسی کاربرد شبکه های عصبی در رتبه بندی اعتباری فروش اقساطی متقاضیان وام پرداختند و مدل شبکه عصبی برای طبقه بندی متقاضیان دریافت وام فروش اقساطی ارائه و عملکرد این مدل را با دو مدل

1 Trinkle

2 Malhotra, R & Malhotra, D.K,2003

3 Kim & Sohn,2004

آماري آناليز ممیزی و رگرسیون لجستیک مقایسه کردند و نشان دادند که مدل شبکه عصبی در مقایسه با سایر مدل های مورد مطالعه، از کارایی و دقت بالاتری برخوردار است.

## ۲- شبکه عصبی مصنوعی<sup>۱</sup> و ویژگی های آن

شبکه عصبی مصنوعی برای مدل سازی معادلات پیچیده و غیرخطی در شاخه علوم کامپیوتر و هوش مصنوعی ارائه شده است. ساختار سلولهای عصبی انسان ایده اولیه شکل گیری شبکه های عصبی مصنوعی بوده است. اولین مدل شد شبکه عصبی مصنوعی توسط راسن بلات<sup>۲</sup> در سال 1958 ارائه ولی مدل شبکه عصبی با پس انتشار خطا در سال ۱۹۸۶ و توسط رامل هارت<sup>۳</sup> ارائه شد که کاربرد زیادی در زمینه هوش مصنوعی و تحلیل های پیچیده در زمینه های مختلف پیدا کرده است. قدرت شبکه های عصبی مصنوعی در مدلسازی ارتباطات پیچیده متغیرها، این تکنیک را به یک ابزار قوی در زمینه تحلیلهای چند متغیره و مدل سازی ارتباطات پیچیده بین متغیرها تبدیل کرده است.

شبکه عصبی مصنوعی یک نمونه سیستم پردازش است که در آن از سیستم های عصبی بیولوژیک مانند مغز الهام گرفته شده است. عضو کلیدی این ساختار جدید سیستم پردازنده اطلاعات است که تعداد زیادی از آن ها به صورت مجتمع مانند هورمون های مغز با یکدیگر کار می کنند تا بتوانند مسائل خاصی مانند تشخیص الگو یا طبقه بندی داده ها را از طریق فرایند یادگیری حل کنند.

یادگیری در شبکه های عصبی به دو صورت است:

۱- تحت نظارت<sup>۴</sup>

۲- بدون دخالت انسان<sup>۵</sup>

یادگیری در شبکه های عصبی رایج به شکل یادگیری تحت نظارت است. در واقع کار شبکه های عصبی مانند یادگیری کودکان است. با نشان دادن اشیاء ماهیت هر شیء برای کودک مشخص می شود. ANN شاخه ای از زمینه هوش مصنوعی یا سیستم های خبره است که با منطق فازی مرتبط است. یک شبکه عصبی مصنوعی می تواند به عنوان یک جعبه سیاه در نظر گرفته شود که قادر است الگوهای خروجی را پس از تشخیص الگوهای ورودی گزارش دهد. شبکه های عصبی در واقع مثلثی هستند که سه ضلع مفهومی دارند:

۱- سیستم تجزیه و تحلیل داده ها

۲- نوروں یا سلول عصبی

1 Artificial Neural Network (ANN)

2 Rosenblatt

3 Rumelhart

4 Supervised

5 Unsupervised

## ۳- شبکه یا قانون کار گروهی نورون ها

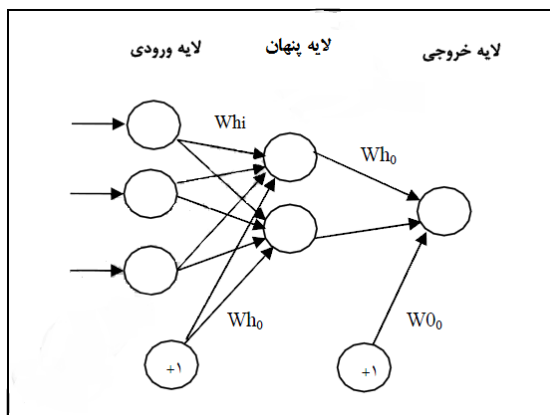
شبکه های عصبی مرحله ای موسوم به یادگیری دارند که شبیه مغز عمل می کنند. نورون ها با پردازشگرهای شبکه به صورت غیر مستقیم به کانال های ارتباطی مرتبط هستند که وظیفه حمل داده ها را بر عهده دارند و تنها بر روی داده های محلی خود که به عنوان ورودی از طریق کانال های ارتباطی دریافت می دارند، عمل می کنند. این شبکه ها به صورت چندلایه<sup>۱</sup> هستند که تعداد لایه های آن بستگی به پیچیدگی مسئله دارند و تعداد لایه ها و تعداد گره ها در هر لایه مخفی از پارامترهایی است که توسط کاربر قابل تنظیم است. هر چه تعداد لایه ها بیشتر باشد سیستم قادر به درک پیچیدگی های بیشتری است. در این شبکه ها با پردازش موازی از طریق وزن ها سیناسپی داده ها راه خود را باز کرده و جلوی داده های دامپ<sup>۲</sup> (داده های دارای خطا یا بی ربط) گرفته می شود. طرز کار یک مدل سلول عصبی بدین صورت است که خطوط یا کانال های ورودی، سیگنال های تحریکی یا مهاری را که همان پارامترهای تعریف کننده سیستم هستند به جسم سلولی یا گره های عصبی می آورند. در ابتدای هر کانال یک ضریب عددی (وزن سیناسپی) وجود دارد که شدت تحریک در آن ضرب می شود. اگر مثبت باشد یک سیگنال تحریکی و اگر منفی باشد یک سیگنال مهاری است؛ این سیگنال های تحریکی یا مهاری که از ورودی های مختلف به جسم سلولی می رسند، با هم به صورت خطی جمع می شود. اگر از میزان آستانه کمتر باشد سلول عصبی خاموش شده و در غیر این صورت شلیک<sup>۳</sup> می شود و جریان الکتریکی ثابتی در خروجی ایجاد می کند که به سلول های دیگر وارد می شود. مشکل شبکه های عصبی این است که به تدریج به حفظ کردن الگوها می پردازند و قابلیت تجزیه و تحلیل آن ها کم می شود، برای رفع این مشکل بایستی تعداد گره ها کم شود، در این صورت شبکه مجبور به تعمیم می شود. شبکه های عصبی مصنوعی برای حل مسائل پیچیده یا مواردی که هیچ راه حل الگوریتمی وجود ندارد یا بسیار پیچیده هستند مورد استفاده قرار می گیرد.

مدل های شبکه عصبی مصنوعی مدل های محاسباتی هستند که قادرند رابطه بین ورودی ها و خروجی های یک دستگاه را با شبکه ای از گره های متصل به هم تعیین می نماید.

---

1 Multilayer  
2 dump  
3 fire

شکل ۱ - نمایش شبکه عصبی



چهار نوع هدف کلی توسط این شبکه‌های قابل پیگیری است، که هر کدام بسته به نوع مجهولات در مواردی خاص قابل بهره‌گیری است:

#### ۱- طبقه بندی

برای طبقه بندی، داده‌های نمونه‌های مختلف به شبکه داده می‌شود و نام گروه هر نمونه به عنوان خروجی مشخص می‌شود، پس از آموزش مناسب شبکه قادر خواهد بود با دریافت داده‌های مربوط به نمونه‌های جدید مشخص کند که این نمونه به کدام طبقه متعلق است. به عنوان مثال می‌توان پارامترهای آزمایشگاهی بیماران مبتلا به سرطان پروستات و افراد سالم را به عنوان ورودی و وضعیت فرد (سالم بودن یا سرطانی بودن) را به عنوان خروجی به شبکه داده در این صورت شبکه پس از یادگیری خواهد توانست پارامترهای فرد جدید را گرفته و سرطانی بودن او را پیشگویی کند.

#### ۲- تخمین تابع

زمانی که پارامترهای ورودی با تأثیرات پیچیده در سیستم پاسخی قابل اندازه‌گیری ایجاد می‌کنند، شبکه می‌تواند آموزش بیابد تا این پاسخ را پیشگویی کند. به عنوان مثال شبکه می‌تواند پس از آموزش، با دریافت داده‌های مربوط به هر مولکول جدید در داروها، شدت اثر آن را پیشگویی کند.

#### ۳- پیشگویی

اصطلاح پیشگویی در اینجا برای سری‌های زمانی به کار برده می‌شود؛ یعنی جایی که داده‌ها مربوط به نمونه‌های پیاپی هستند و داده‌های هر نمونه برای پیشگویی نمونه بعدی استفاده می‌شود. مانند پیشگویی وضعیت آتی بیمار بستری در بخش CCU.

#### ۴- خوشه کردن



این نوع کارکرد شبکه‌ها مربوط به یادگیری<sup>1</sup> است. یعنی طبقه‌بندی داده‌ها بر حسب رفتار و برهم کنش‌های درونی آن‌ها بدون داشتن الگو یا فرضیه قبلی است. همانطور که بیان شد، شبکه‌های عصبی تقریبی از رفتار مغز و اعصاب در قسمت‌های مختلف بدن موجودات زنده هستند و دارای قابلیت‌های مختلف بر اساس کاربرد می‌باشند. شبکه‌های عصبی یک پردازشگر موازی است که در یک لحظه دارای آموزش و اعمال می‌باشند و دارای محاسبات قوی و ارزشمند از داده و اطلاعات هستند.

در ساختار شبکه‌های عصبی که دارای نرون‌ها و لایه‌های زیاد هستند باعث انعطاف پذیری و درجه آزادی زیاد در سیستم عصبی می‌شوند ولی زمان محاسبات طولانی‌تر خواهد شد اما دارای توانایی زیاد در اصلاح و تعمیم پذیری می‌باشند و دارای قابلیت حذف اغتشاش و نویز هستند. همچنین قابلیت تولید الگوریتم تطبیق پذیر هوشمند بر پایه کاربرد را دارند.

تاکنون مدل‌های مختلف با ساختار و الگوریتم‌های متنوعی از شبکه‌های عصبی ارائه شده است و هر چند این مدل‌ها با یکدیگر تفاوت دارند، اما تمام این مدل‌ها یک هدف مشترک را دنبال می‌کنند. به طور کلی سلول‌های عصبی که تشکیل دهنده یک شبکه عصبی می‌باشند ماشین‌های محاسباتی هستند، که از اجزای ساده (سلول) و زنجیره‌ای تشکیل می‌شوند و دارای خواص زیرند:

➤ قابلیت یادگیری و تطبیق پذیری

➤ قابلیت تعمیم پذیری

➤ پردازش موازی

➤ مقاوم بودن

➤ قابلیت تقریب عمومی

قابلیت یادگیری یعنی توانایی تنظیم پارامترهای شبکه عصبی. برای این منظور نمونه‌های اولیه را به شبکه اعمال می‌کنند شبکه، پارامترها را بر اساس این نمونه‌ها تنظیم می‌کند. اگر نمونه‌های جدید به این شبکه که به این طریق آموزش دیده، اعمال شود، خروجی مناسب را با درصد خطای کوچک می‌توان بدست آورد. با این ترتیب شبکه‌های عصبی می‌توانند با تغییر شرایط به صورت هوشمندانه، خود را تطبیق یا اصلاح نمایند.

قابلیت تعمیم پذیری یعنی پس از آنکه نمونه‌های اولیه به شبکه آموزش داده شد، شبکه می‌تواند در مقابل ورودی‌های آموزش داده نشده (ورودی‌های جدید) قرار گیرد و یک خروجی مناسب تولید نماید. این خروجی بر اساس مکانیسم تعمیم، که چیزی جز فرایند درون‌یابی نیست به دست می‌آید.

پردازش موازی یعنی هنگامی که شبکه عصبی در قالب سخت افزار پیاده می‌شود سلولهایی که در یک تراز قرار می‌گیرند می‌توانند به طور همزمان به ورودیهای آن تراز پاسخ دهند. این ویژگی باعث افزایش سرعت پردازش می‌شود. در واقع در چنین سیستمی، وظیفه کلی پردازش بین پردازنده های کوچکتر مستقل از یکدیگر توزیع می‌گردد.

مقاوم بودن یعنی در یک شبکه عصبی رفتار کلی آن مستقل از رفتار هر سلول در شبکه می‌باشد در واقع رفتار کلی شبکه برآیند رفتارهای محلی تک تک سلولهای شبکه می‌باشد که این امر باعث می‌شود تا خطا های محلی سلولها از چشم خروجی نهایی دور بمانند. این خصوصیت باعث افزایش قابلیت مقاوم بودن در شبکه عصبی می‌گردد.


قابلیت تقریب عمومی یعنی شبکه های عصبی چند لایه، با یک یا چند لایه مخفی به شرط آن که تعداد نرونهای لایه ها مخفی کافی داشته باشند، می‌توانند هر تابع غیر خطی پیوسته ای را در فضای ترکیبی تخمین بزنند.

### ۳- ساختار شبکه پرسپترون چند لایه

یک شبکه معمولاً از تعدادی لایه تشکیل می‌شود. در یک شبکه پرسپترون چند لایه (MLP) تمامی نرونهای ورودی در یک لایه ورودی و تمامی نرونهای خروجی در یک لایه خروجی و تمامی نرون های پنهان در یک یا چند لایه پنهان توزیع می‌شوند. در طراحی این شبکه باید متغیرهای مانند تعداد نرونهای ورودی، تعداد لایه های پنهان و نرون های پنهان و تعداد نرونهای خروجی تعیین شود. تعداد نرونهای ورودی برابر با تعداد متغیرهای بردار ورودی مورد استفاده برای پیش بینی مقادیر آینده متغیر مورد بررسی است. برای پیش بینی عالی، تعداد ورودی ها مشخص و به راحتی قابل تعیین است. برای پیش بینی سری زمانی، تعداد نرون های ورودی برابر با تعداد مشاهدات با وقفه ای است که برای کشف الگوی موجود در داده ها و پیش بینی مقادیر آینده آن به کار می‌رود. وجود تعداد خیلی کم یا خیلی زیاد از نرونهای ورودی می‌تواند قابلیت یادگیری و پیش بینی شبکه را تحت تأثیر قرار دهد. بنابراین، تعیین تعداد نرونهای ورودی مهمترین عامل در پیش بینی سری زمانی است؛ زیرا حاوی اطلاعات بسیار مهمی در خصوص ساختار خود همبستگی پیچیده (خطی یا غیرخطی) داده ها است. نرونهای لایه های پنهان نیز نقش بسیار مهمی در به کارگیری موفقیت آمیز یک شبکه دارند. در واقع این نرون های پنهان در لایه های پنهان هستند که به شبکه اجازه کشف ویژگی ها، شکار الگوی موجود در داده ها و طرح ریزی یک نقشه غیرخطی کاملاً پیچیده میان متغیرهای ورودی و خروجی را می‌دهند. باید توجه داشت که در صورت نبود نرون های پنهان، پرسپترون های ساده با نرون های خروجی خطی، کارکردی همانند کارکرد مدل های آماری خطی برای پیش بینی دارند. یک شبکه عصبی مصنوعی با یک لایه پنهان می‌تواند هر تابع غیرخطی پیچیده را با هر درجه از دقت تقریب بزند (هورنیک و دیگران، ۱۹۸۹) از این رو، بیشتر پژوهشگران از یک لایه مخفی برای

پیش بینی استفاده می کنند. یک لایه پنهان به تعداد زیادی نرون پنهان احتیاج دارد و این امر زمان آموزش را بسیار طولانی می کند. معمول ترین روش برای تعیین تعداد نرونهای پنهان و لایه های پنهان روش تجربی یا آزمون و خطا<sup>۱</sup> است. تعداد نرونهای خروجی معمولاً به سادگی و با توجه به موضوع مورد مطالعه تعیین می شود .

نرون های موجود در لایه بالادست به نرون های موجود در لایه پایین دست ارتباط دارند. نقش هر نرون محاسبه مجموع وزن داده شده نرون ورودی و سپس گذراندن این مجموع از یک تابع به نام تابع انتقال می باشد. تابع انتقال می تواند یک تابع خطی یا غیرخطی باشد. دو نوع از توابع مرسوم در شبکه پرسپترون چندلایه، تابع سیگموئید و تانژانت هایپر بولیک می باشد که در شکل های زیر این توابع نشان داده شده اند.



شکل ۲- تابع سیگموئید

شکل ۱- تابع تانژانت هایپر بولیک

برای مسأله پیش بینی سری زمانی، تعداد نرونهای خروجی به افق پیش بینی<sup>۲</sup> بستگی دارد. دو نوع پیش بینی به صورت پیش بینی یک گام به جلو شامل یک نرون خروجی و پیش بینی چند گام به جلو شامل یک یا چند نرون خروجی وجود دارد. برای پیش بینی به صورت چندگام به جلو نیز دو روش وجود دارد. روش اول که در روش باکس- جنکینز نیز از آن استفاده می شود، عبارت از پیش بینی تکراری است. در این روش فقط به یک نرون خروجی نیاز است و در آن مقادیر پیش بینی به صورت تکراری به عنوان ورودی برای پیش بینی های آینده به کار می رود. روش دوم روش مستقیم است. در این روش به شبکه اجازه داده می شود که چندین نرون خروجی داشته باشد. به نظر می رسد که روش مستقیم روش بهتری باشد (ژانگ و ترلین<sup>۳</sup>، ۱۹۹۴)

#### ۴- روش تحقیق:

مدل های رتبه بندی اعتباری، یکی از مهمترین و اساسی ترین سیستم های تصمیم گیری هستند که بخش عمده ای از اطلاعات مورد نیاز موسسات اعتباردهنده در مدیریت اعتبار را فراهم می کنند. هدف مدل های رتبه بندی اعتباری، پیش بینی احتمال عدم بازپرداخت اعتبار از سوی مشتریان و یا طبقه بندی متقاضیان

1 Trial and Error  
2 Forecasting Horizon  
3 Zhang and Thearling

اعتبار به دو گروه خوب و بد است. به عبارت دیگر، رتبه بندی اعتباری مجموعه ای از مدل های تصمیم گیری و روش های مرتبط با آنهاست که به اعتبار دهندگان در اعطای اعتبار به مشتریان کمک می کند. در این مقاله هدف اصلی، استفاده و معرفی مدل‌های شبکه عصبی در رتبه بندی اعتباری متقاضیان وام است، لذا مدل اصلی استفاده شده برای طبقه بندی، یک مدل شبکه عصبی پرسپترون چندلایه با الگوریتم یادگیری پس انتشار خطاست.

از اطلاعات مربوط به ۸۵۰ مشتری که در فایل داده های bankloan.sav موجود است استفاده می کنیم. ۷۰۰ مورد اول مشتریانی هستند که قبلاً وام گرفته بودند. با استفاده از نمونه گیری تصادفی از این ۷۰۰ مشتری یک پرسپترون چند لایه ای ایجاد می کنیم و باقی مشتریان را برای تحلیل رتبه بندی بکار می گیریم. بنابر این از مدل برای طبقه بندی ۱۵۰ مشتری آینده به عنوان مشتریان خوش ریسک یا بد ریسک استفاده می کنیم. در اینجا مامور بانک داده ها با استفاده از رگرسیون لجستیک، داده ها را تحلیل نموده و می خواهد بداند چگونه پرسپترون چند لایه ای به عنوان ابزار طبقه بندی استفاده می شود. انتخاب اعضای تصادفی به ما این اجازه را می دهد که تحلیل ها را به درستی تکرار کنیم. در تحلیل رگرسیونی که مامور بانک قبلاً انجام داده است حدود ۷۰٪ مشتریان گذشته در نمونه ی یادگیری ثبت شده اند و ۳۰٪ باقیمانده در نمونه اعتبار. این نشان می دهد که نیاز به یک متغیر دسته بندی داریم تا به طور دقیق نمونه های لازم در این تحلیل ها را ایجاد کند.

متغیر افرادی که قبلاً در وام تاخیر داشتند<sup>۱</sup> را به عنوان متغیر وابسته و متغیر سطح تحصیلات<sup>۲</sup> را به عنوان کووریت<sup>۳</sup> انتخاب می کنیم. بعد از مدلسازی و وارد کردن متغیرهای وابسته و مستقل در مدل، خروجی های مدل را بصورت زیر تفسیر می کنیم.

جدول ۱ - خلاصه فرآیند شبکه

	N	Percent
Sample Training	499	71.3%
Holdout	201	28.7%
Valid	700	100.0%
Excluded	150	
Total	850	

نتایج نشان می دهد که ۴۹۹ مورد در نمونه یادگیری ثبت شده اند و ۲۰۱ داده در نمونه بیرون نگاه داشته و به عنوان اعتبار ثبت شده اند. ۱۵۰ داده ای که از تحلیل دور نگه داشته شده اند همان مشتریان مربوط به آینده می باشد. جدول زیر اطلاعات درباره شبکه عصبی ساخته شده ارائه می دهد و برای تضمین اینکه تصریح درست بوده است، مفید می باشد.

1 previously defaulted

2 level of education

3 covariates

جدول ۲ - اطلاعات شبکه

Input Layer	Factors	1	Level of education
	Covariates	1	Age in years
		2	Years with current employer
		3	Years at current address
		4	Household income in ...
		5	Debt to income ratio (x100)
		6	Network information <sup>a</sup> debt in thousands
7	Other debt in thousands		
	Number of Units <sup>a</sup>	12	
	Rescaling Method for Covariates		Standardized
Hidden Layer(s)	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1 <sup>a</sup>		4
Output Layer	Activation Function		Hyperbolic tangent
	Dependent Variables	1	Previously defaulted
	Number of Units		2
	Error Function		Cross-entropy

<sup>a</sup>Excluding the bias unit

جدول ۳ - خلاصه مدل

Training	Cross Entropy Error	156.606
	Percent Incorrect Predictions	15.6%
	Stopping Rule Used	Maximum number of epochs (100) exceeded
	Training Time	00:00:00.081
Holdout	Percent Incorrect Predictions	25.4%

Dependent Variable: Previously defaulted

جدول ۳ خلاصه ی مدل، اطلاعاتی را ارائه می دهد که در باره نتایج یادگیری و کاربرد شبکه نهایی راجع به نمونه بیرون و اعتبار است.

از میان مواردی که مدل ایجاد کرده است ، ۷۴ نفر از ۱۲۴ نفر از افرادی که قبلا تاخیر در پرداخت وام داشتند<sup>۱</sup> بدرستی دسته بندی شده اند. ۱۷۴ نفر از ۳۷۵ نفر از کسانی که تاخیر نداشتند هم به درستی دسته بندی شده اند . بطور کلی ۸۴.۴٪ از موارد یادگیری بدرستی دسته بندی شده است در مقابل ۱۵.۶٪ نادرست نشان داده شده اند که در جدول خلاصه مدل نشان داده شده . یک مدل بهتر باید بدرستی یک درصد بالاتری از این موارد را مشخص کند.

دسته بندی های بر اساس مورد ها معمولا مدلی را می سازد که تمایل به خوش بینی در نرخ دسته بندی و طبقه بندی دارد و آنها را متورم تر نشان می دهد. نمونه خارج مانده یا اعتبار برای بررسی اعتبار مدل کمک

<sup>1</sup> previously defaulted

می‌کند. در اینجا ۷۴.۶٪ از این موارد بوسیله مدل به درستی دسته‌بندی شده‌اند. این روش پیشنهاد می‌دهد که به طور کلی در وقع مدل مورد نظر ۳/۴ صحت دارد.

در تحلیل‌های رگرسیون لجستیک که مامور بانک قبلاً انجام داده بود، نمونه‌های یادگیری و اعتبار همین در صد‌ها را به درستی پیش‌بینی می‌کردند (حدود ۸۰٪). در شبکه عصبی در صد بیشتری از پیش‌بینی درست را در نمونه یادگیری یک پیش‌بینی ضعیف‌تر در نمونه اعتبار برای پیش‌بینی مشتریانی که حقیقتاً تاخیر داشتند انجام شده است (۴۵.۸٪ درست برای نمونه اعتبار در مقابل ۵۹.۷٪ درست برای نمونه یادگیری). با ترکیب فائده توقف که در جدول خلاصه مدل گزارش داده شد، به این نتیجه می‌رسیم که شبکه باید بازنویسی شود یعنی به دنبای الگویی بهتر باشیم که در داده‌های یادگیری بوسیله تغییرات تصادفی ظاهر می‌شود.

با تعریف یک نمونه آزمون برای کمک به اجرای شبکه متغیر تقسیم‌بندی<sup>۱</sup> را قبلاً درست شبیه تحلیل‌های رگرسیون لجستیک ساختیم که هیچ مفهومی از نمونه آزمون وجود نداشت. حال سهمی از نمونه یادگیری را برداریم و به عنوان نمونه آزمون تعریف می‌کنیم. خروجی‌های مدل به این صورت می‌باشد:

جدول ۴- خلاصه فرآیند شبکه

	N	Percent
Sample Training	398	56.9%
Testing	101	14.4%
Holdout	201	28.7%
Valid	700	100.0%
Excluded	150	
Total	850	

از بین ۴۹۹ موردی که قبلاً موردی که قبل جزو نمونه یادگیری ثبت شده بودند حال ۱۰۱ مورد جزو نمونه آزمون دوباره ثبت شدند. تنها در جدول اطلاعات شبکه تغییر بوجود آمده است و این است که ساختار انتخاب شده در ۷ واحد در لایه پنهان است.

جدول ۵ - اطلاعات شبکه

Input Layer	Factors	1	Level of education
	Covariates	1	Age in years
		2	Years with current employer
		3	Years at current address
		4	Household income in ...
		5	Debt to income ratio (x100)
		6	Credit card debt in thousands
7	Other debt in thousands		
	Number of Units <sup>a</sup>	12	
	Rescaling Method for Covariates		Standardized
Hidden Layer(s)	Number of Hidden Layers	1	
	Number of Units in Hidden Layer 1 <sup>a</sup>	7	
Output Layer	Activation Function		Hyperbolic tangent
	Dependent Variables	1	Previously defaulted
	Number of Units	2	
	Error Function		Cross-entropy

a.Excluding the bias unit

همانطور که مشاهده می‌شود در پیش‌بینی‌های غلط، میان نمونه‌های یادگیری آزمون و اعتبار برابر است. الگوریتم برآورد متوقف شده زیرا که خطا از این مرحله به بعد افزایش نداشته است. همچنین این نتایج پیشنهاد می‌دهد که مدل اولیه شاید در واقع یادگیری مازاد داشته و این مساله بوسیله‌ی اضافه کردن نمونه آزمون حل شده است و البته اندازه‌های نمونه کوچک است.

جدول ۶ - خلاصه فرایند مدل

Training	Cross Entropy Error	159.870
	Percent Incorrect Predictions	20.1%
	Stopping Rule Used	1 consecutive step (s) with no decrease in error <sup>a</sup>
	Training Time	00:00:01.013
Testing	Cross Entropy Error	40.068
	Percent Incorrect Predictions	17.8%
Holdout	Percent Incorrect Predictions	20.4%

Dependent Variable: Previously defaulted

a.Error computations are based on the testing sample.

جدول دسته‌بندی<sup>۱</sup> نشان داد که استفاده از مرز و نقطه قطع احتمال کاذب ۰.۵ برای دسته بندی، شبکه در پیش‌بینی تاخیر‌داران نسبت به تاخیرداران بهتر عمل نموده است.

جدول ۷ - جدول دسته بندی


Sample	Observed	Predicted		
		No	Yes	Percent Correct
Training	No	263	34	88.6%
	Yes	46	55	54.5%
	Overall Percent	77.6%	22.4%	79.9%
Testing	No	73	5	93.6%
	Yes	13	10	43.5%
	Overall Percent	85.1%	14.9%	82.2%
Holdout	No	124	18	87.3%
	Yes	23	36	61.0%
	Overall Percent	73.1%	26.9%	79.6%

Dependent Variable: Previously defaulted

مقادیر قطع و انفصال یک دید محدود از توانایی پیش بینی شبکه به شما می دهد. در نتیجه این قسمت برای مقایسه با شبکه های رقیب زیاد جالب بنظر نمی رسد بنابراین برای مقایسه بهتر نمودار راک کرو<sup>۱</sup> را رسم می کنیم. نمودار راک کرو بوسیله دو معیار حساسیت و تصریح، الگوی مناسب برای طبقه بندی ریسک های خوب و بد اعتباردهی برای پیش بینی خوش اعتباری و بد اعتباری مشتریان ارائه می دهد و کارایی و دقت مدل شبکه عصبی مصنوعی را در رتبه بندی اعتباری بررسی خواهیم کرد.

معیار حساسیت<sup>۲</sup>: معیاری برای سودمندی و فایده الگوی طبقه بندی است. این حساسیت احتمال این است که حالت های مثبت به درستی دسته بندی شود و و روی محور Y در نمودار راک کرو رسم می شود. مقدار ۱ برای حساسیت بیانگر نرخ منفی غلط می باشد.

معیار صراحت<sup>۳</sup>: این معیار نیز برای سودمندی و فایده الگوی طبقه بندی است. این حساسیت احتمال این است که حالت های منفی به درستی دسته بندی شود و روی محور X در نمودار راک کرو رسم می شود. مقدار ۱ برای حساسیت بیانگر نرخ مثبت غلط می باشد.




نمودار موجود در اینجا دو منحنی را نشان می دهد. یکی برای گروه NO و دیگری برای گروه YES می باشد. از آنجا که تنها دو گروه وجود دارد منحنی ها نسبت به خط ۴۵ در جه متقارن می باشد. این نمودار بر اساس نمونه های یادگیری و آزمون می باشد .

1 ROC Curve  
2 sensitivity  
3 specificity



		Area
Previously defaulted	No	.853
	Yes	.853

سطح زیر نمودار یک خلاصه‌ی عددی از راک کرو است و مقادیر داخل جدول، برای هر دسته، احتمال پیش‌بینی و احتمال کاذب بودن در آن دسته برای یک حالت تصادفی انتخاب شده بیشتر از این احتمال است که حالت تصادفی خارج از این دسته انتخاب شود را ارائه می‌دهد. سطح زیر نمودار آماره‌ای خلاصه برای دقت شبکه است. در این جا لازم است قادر باشیم معیار خاصی بوسیله مشتریان طبقه‌بندی شده انتخاب کنیم. نمودار پیش‌بینی با مشاهدات یک شروع بصری در این مرحله به ما می‌دهد.



برای متغیر وابسته دسته‌بندی شده نمودار پیش‌بینی با مشاهدات، یک نمودار جعبه‌ای خوشه‌ای از احتمالات کاذب برای نمونه‌های یادگیری و آزمون ارائه می‌دهد. محور X مطابق با دسته‌های پاسخ مشاهده شده است و علائم و اختصارات مطابق با دسته‌بندی‌های پیش‌بینی شده است.


شکل اول در سمت چپ نمودار نشان‌دهنده حالت‌هایی است که  $\pi_0$  مشاهده شده است یعنی احتمال کاذب پیش‌بینی شده برای دسته  $\pi_0$  می‌باشد. قسمتی از نمودار جعبه‌ای که بالای ۰.۵ روی محور Y قرار دارد بیانگر پیش‌بینی‌های درست است که در جدول دسته‌بندی نشان داده شده بود. و قسمتی از نمودار جعبه‌ای که پایین‌تر از ۰.۵ است بیانگر پیش‌بینی‌های نادرست است. از جدول دسته‌بندی به یاد آورید

که شبکه در پیش بینی حالت هایی با دسته بندی NO با نقطه انفصال ۰.۵ بسیار خوب عمل می کرد. بنابراین و شاید تنها بخشی از از ریسک دارهای پایینی و بعضی موارد پرت در دسته بندی قرار نگیرند. شکل دوم از سمت چپ در نمودار نشان دهنده حالتی است که NO مشاهده شده است و احتمال پیش بینی کاذب در دسته YES می باشد. از آنجا که تنها دو دسته در متغیر هدف وجود دارد، دو نمودار اول نسبت به خط افقی ۰.۵ متقارن هستند.

سومین نمودار از سمت چپ بیانگر حالت هایی که دسته مشاهده شده YES می باشد و احتمال کاذب پیش بینی در دسته NO می باشد. این نمودار و نمودار آخری نسبت به خط افقی ۰.۵ متقارن اند.

آخرین نمودار از سمت چپ برای حالت هایی است که در دسته بندی YES مشاهده شده است و احتمال کاذب پیش بینی در دسته YES بوده است. قسمتی از نمودار جعبه ای که بالای ۰.۵ است بیانگر پیش بینی های درست است که در جدول نشان داده شده است. از جدول دسته بندی به یاد داریم که پیش بینی شبکه کمی بیشتر از نصف حالت ها با دسته بندی YES با استفاده از نقاط انفصال ۰.۵ بود، بنابراین قسمت خوب این جعبه دسته بندی نشده است.

با مشاهده به نمودار اینگونه بنظر می رسد که با کم کردن نقطه انفصال برای دسته بندی یک حالت به عنوان YES به حدود ۰.۳، این حدودا همان مقداری است که بالای جعبه ی دوم و پایین جعبه ی چهارم است، این کاهش نقطه انفصال باعث می شود که به تاخیر داران آینده دست یابیم بدون اینکه هیچ مشتری خوب بالقوه را از دست دهیم. یعنی حرکت از ۰.۵ به ۰.۳ در طول جدول دوم باعث دسته بندی مجدد و غلط نسبتا کمی از مشتریان تاخیر ندار در طول چهارچوب به عنوان تاخیر داران پیش بینی شده می شود. در حالی که در طول جعبه چهارم این حرکت نقطه انفصال باعث می شود بسیاری از تاخیر داران داخل جعبه به درستی به عنوان تاخیر داران پیش بینی شده دسته بندی شدند.



نمودار سود انباشته<sup>۱</sup> درصد کل تعداد حالتهایی را در یک دسته مشخص gain بوسیله هدف گیری یک درصد تعداد کل حالات را در نظر می‌گیرد. برای مثال اولین نقطه روی منحنی برای دسته بندی yes در نقطه (۳۰٪ و ۱۰٪) به معنای این است که اگر یک مجموعه داده را در شبکه دسته بندی کنیم و همه موارد را با احتمالات پیش بینی کاذب yes مرتب کنیم، انتظار خواهیم داشت ۱۰ درصد بالایی تقریباً ۳۰ درصد همه مواردی است دقیقاً در دسته yes قرار دارند (یعنی تاخیر داران). به همین صورت ۲۰ درصد بالایی که شامل ۵۰ درصد تاخیر داران است و ۳۰ درصد حالات شامل ۷۰ درصد تاخیر داران<sup>۲</sup> است. اگر ۱۰۰ درصد مجموعه داده‌های امتیاز بندی را انتخاب کنیم، به همه تاخیرداران در مجموعه داده‌ها دست خواهیم یافت. خط قطری خط پایه منحنی است. اگر ۱۰ درصد موارد از داده‌های امتیاز بندی شده را به صورت تصادفی انتخاب کنیم انتظار خواهیم داشت که تقریباً ۱۰ درصد همه حالت‌هایی را که واقعا yes هستند را سود<sup>۳</sup> کنیم. هر چه از خط پایه نمودار بالاتر رویم سود بیشتری می‌بریم. میتوان از نمودار سود تجمعی برای کمک گرفتن برای انتخاب یک نقطه انفصال بوسیله انتخاب درصدی که مربوط به سود مورد نظر است استفاده نمود. سپس می‌توان درصد سود دلخواه را با مقدار نقطه انفصال مورد نظر ردیابی نمود.

آنچه که یک سود مورد نظر را می‌سازد بستگی به هزینه‌های نوع اول و نوع دوم دارد. یعنی هزینه اینکه یک تاخیردار را جزو تاخیر ندار دسته بندی کنیم (خطای نوع اول) و هزینه اینکه یک تاخیر ندار را به عنوان تاخیر دار دسته بندی کنیم (خطای نوع دوم) چیست. اگر بدحسابی اولین اهمیت و نگرانی باشد آنگاه می‌خواهیم که خطای نوع اول را کاهش دهیم. در نمودار سود تجمعی این ممکن است متناظر با رد وام به متقاضیانی باشد که جزو ۴۰ درصد بالای احتمال پیش بینی کاذب yes باشند که حدود ۹۰ درصد افراد تاخیر دار می‌باشد اما تقریباً نزدیک نیمی از جمع متقاضیان را از بین می‌برد.


اگر افزایش تعداد مشتریان هدف اصلی است آنگاه باید خطای نوع اول را کم کرد. در نمودار این می‌تواند متناظر با این باشد که رد ۱۰ درصد اولیه که ۳۰ درصد تاخیر داران را به تصویر می‌کشد و بقیه جمعیت مشتریان را از دست می‌دهیم. معمولاً هر دو موضوع اهمیت دارد هم بدحسابی هم افزایش تعداد مشتریان. بنابراین این مجبور خواهیم بود یک تصمیم برای دسته بندی مشتریان که بهترین ترکیب حساسیت و تصریح را می‌دهد انتخاب کنیم.

---

1 cumulative gain chart

2 defaulter

3 gain



نمودار ترقی<sup>۱</sup> از نمودار سود تجمعی بدست می‌آید. مقادیر روی محور X متناظر با نرخ سود تجمعی برای هر نمودار نسبت به خط اصلی است و بنابر این افزایش در ۱۰٪ برای دسته بندی Yes ۳۰٪ می‌باشد. این راه دیگر برای این فراهم می‌سازد که اطلاعات را از روی نمودار سود تجمعی بدست آوریم. نمودارهای ترقی و سود انباشته بر اساس نمونه‌های یادگیری و تست (آزمون) می‌باشد.

	Importance	Normalized Importance
Level of education	.032	11.9%
Age in years	.075	27.9%
Years with current employer	.268	100.0%
Years at current address	.166	61.8%
Household income in thousands	.033	12.2%
Debt to income ratio (x100)	.125	46.5%
Credit card debt in thousands	.213	79.3%
Other debt in thousands	.090	33.6%


اهمیت یک متغیر مستقل این است که معیار برای اینکه چقدر ارزش مدل پیش‌بینی شده شبکه، برای مقادیر مختلف متغیر وابسته تغییر می‌کند. اهمیت هنجار شده و مرسوم این است که مقادیر ارزش بوسیله‌ی مقادیر ارزش بزرگتر تقسیم می‌شود و به عنوان درصد بیان می‌شود. نمودار اهمیت<sup>۲</sup> یک نمودار میله‌ای است از مقادیر اهمیت در جدول اهمیت که به صورت مقادیر کاهشی تنظیم و مرتب شده است. اینگونه بنظر می‌رسد که متغیرهای مرتبط با استحکام مشتریان (مثل آدرس و شغل) و وام<sup>۳</sup> بیشترین اثر را روی مشتریان دسته بندی شده شبکه داشته‌اند. آنچه نمی‌توان پیش‌بینی

<sup>1</sup> lift chart

<sup>2</sup> importance chart

<sup>3</sup> creddebt , debtinc

کرد مسیر و نقشه رابطه بین این متغیر است و اینکه احتمال پیش بینی شده تاخیر دارها است. حدس می‌زنیم که یک تعداد بیشتری از وام بیانگر درست‌نمایی بالاتری از تاخیر داران است اما برای اطمینان نیاز به استفاده از یک مدل ساده‌تر با پارامتر قابل تفسیر بیشتری است.



## ۵- نتیجه‌گیری

با استفاده از فرآیند پرسپترون چند لایه، می‌توان یک شبکه عصبی برای پیش‌بینی احتمالاتی که یک مشتری روی وام تاخیر داشته باشد می‌دهد. نتایج مدل با آنچه از نتایج رگرسیون لجستیک را تحلیل‌های مشخص بدست می‌آید قابل مقایسه است. بنابراین می‌توان بطور منطقی مطمئن باشد داده‌ها شامل روابطی نیست که نتواند توسط آن مدل به تصویر کشیده نشوند. بنابراین می‌توان از آن‌ها برای جستجوی بیشتر ذات روابط بین متغیرهای مستقل و وابسته استفاده کرد. در این مطالعه با استفاده از مطلع بودن ویژگی احتمال دیرکرد در پرداخت وام مشتریان، از این ویژگی‌ها برای شناسایی ریسک خوش‌اعتباری و بد‌اعتباری استفاده شد.

منابع:

۱. آماده، حمید؛ محمود جعفرپور، (۱۳۸۸). «بررسی موانع و راهکارهای توسعه بانکداری الکترونیکی در بانک‌های خصوصی کشور». پژوهشنامه مدیریت اجرایی، علمی - پژوهشی، سال نهم، شماره ۲ (پیاپی ۳۶)، نیمه دوم، ۱۳۸۸.
۲. اخباری، مهدیه؛ مخاطب رفیعی، فریماه. (۱۳۸۹). «کاربرد سیستم‌های استدلال عصبی - فازی در رتبه‌بندی اعتباری مشتریان حقوقی بانک‌ها»، مجله تحقیقات اقتصادی، شماره ۹۲، پاییز ۸۹، صفحات ۲۱-۱.
۳. رجب زاده قطری، علی؛ آرش بهرام میرزایی، پرویز احمدی؛ (۱۳۸۷). «طراحی سیستم هوشمند ترکیبی رتبه‌بندی اعتباری مشتریان بانک‌ها با استفاده از مدل‌های استدلالی فازی ترکیبی». فصلنامه پژوهشنامه بازرگانی، شماره ۵۳، زمستان ۱۳۸۸، ۲۰۱-۱۵۹.

۴. خورشید، صدیقه؛ حمیده قانع، (۱۳۸۸). «رتبه بندی چالش های بانکداری الکترونیکی از دیدگاه مشتریان و مدیران نظام بانکی با استفاده از فرآیند تحلیل سلسله مراتبی فازی». فصلنامه مدیریت صنعتی، دانشکده علوم انسانی دانشگاه آزاد اسلامی، واحد سنندج، سال چهارم، شماره ۹، پاییز ۱۳۸۸.
۵. نیلساز، حمید و همکاران، (۱۳۸۶). «کاربرد شبکه های عصبی در رتبه بندی اعتباری فروش اقساطی متقاضیان وام»، فصلنامه پژوهش های اقتصادی ایران، سال نهم، شماره ۳۲، پاییز ۱۳۸۶، صفحات ۱۰۹-۸۵.
6. Bennell. J.A, Crabbe.D, Thomas. S, Gwilym.O.A, 2006," Modelling Sovereign Credit Ratings: Neural Networks Versus Ordered Probit", *Expert Systems With Applications*, Vol 30, PP. 415-425.
  7. Chang F-Y; Chiu D-Y, 2001; "Simulating the Investors' Decision Making for Financial Investment", *Agenda of the Third Conference on Sustainable Development for Management*, pp. 548-553.
  8. Chen. A-S, Leung.M.T, 2004: "Regression Neural Network for Error Correction in Foreign Exchange Forecasting and Trading", *Computers & Operations Research*, Vol 31, pp. 1049-1068.
  9. Jenson. Herbert, 1992; "Using Neural Network for Credit Scoring", *Managerial Finance* , 18(6), pp. 15-26.
  10. Kim, Y.S. and Sohn, S.Y. (2004). Managing loan customers using misclassification patterns of credit scoring model. *Expert Systems with Applications*, 26, 567-573.
  11. Malhorta., Malhorta.D.K, 2002; "Differentiating Between Good Credits and Bad Credits Using Neuro-Fuzzy Systems", *European Journal of Operation Research*, pp. 190-211.
  12. Malhotra, R. and Malhotra, D.K. (2003). Evaluating consumer loans using neural networks. *Omega*, 31, 83-96.
  13. Ripley B. D. Neural networks as a related methods for classification, *Journal of Royall Statistical Society*. 1994; 56 (3), 409 – 456
  14. Stern S. Neural networks in applied statistics, *American Statistical Association*. 1996; 38 (3), 205 – 215
  15. Thomas, L.C., Edelman, D.B and Crook J.N. (2002). Credit scoring and its applications. Siam, Philadelphia.
  16. Trinkle. B. S, 2006; Interpretable Credit Model Development Via Artificial Neural Network, PhD thesis, University of Alabama.
  17. Wang, S. An insight into the standard back-propagation neural network model for regression analysis. *J. Mgmt. Sci*. 1998; 26 (1), 133 – 140.
  18. West. D, 2000; "Neural Network Credit Scoring Models", *Computers and Operations Research*, Vol 27, pp. 1131-1152.
  19. Zhang M, Zhang JC, Fulcher J, 2000; "Higherorder Neural Network Group Models for Financial Simulation", *International Journal of Neural Network*, Vol 10, Issue 2, pp 123-42