

# طراحی و تبیین مدل کارآمد تخصیص تسهیلات بانکی - رویکرد شبکه‌های عصبی، رگرسیون لجستیک و خطی

علی منصوری<sup>۱</sup>، عادل آذر<sup>۲</sup>

۱ - دانشجوی دکتری مدیریت دانشگاه تربیت مدرس، صندوق پستی ۱۳۹ - ۱۴۱۱۵

۲ - دانشیار دانشگاه تربیت مدرس

## چکیده

هدف اساسی کلیه بانکهای تجاری، جمع‌آوری پس‌اندازهای اشخاص حقیقی و حقوقی و اعطای تسهیلات به سازمانها و شرکتهای مختلف تولیدی، خدماتی، صنعتی و ... می‌باشد. با توجه به اهمیت تسهیلات اعطایی به شرکتهای واجد شرایط مدلهای متعددی برای سنجش ریسک اعتباری آنها ارائه شده است، لکن اغلب مدلهای مورد استفاده در این زمینه از نوع مدلهای خطی و یا خطی تعمیم یافته هستند که فقط ریسک اعتباری مشتریان را تحلیل می‌کنند و مورد بررسی قرار می‌دهند و کمتر به ظرفیت اعتباری مشتریان که عامل مهمی در ارائه تسهیلات اعتباری به شمار می‌رود توجه نموده‌اند. در این مقاله با استفاده از یک سری متغیرهای مستقل و بهره‌گیری از شبکه‌های عصبی پرسپترون چند لایه، ریسک اعتباری و ظرفیت اعتباری شرکتهای و سازمانهای درخواست‌کننده اعتبار به طور همزمان مورد تحلیل قرار گرفته است. به منظور سنجش کارایی مدلهای شبکه‌های عصبی در مقایسه با مدلهای کلاسیک، نتایج حاصل از این مدل با نتایج مدلهای رگرسیون خطی و لجستیک مقایسه شده است. بررسی نتایج نشان داد که مدلهای شبکه‌های عصبی و رگرسیون لجستیک در بر آورد ریسک اعتباری از قابلیت مشابهی برخوردار هستند، لکن مدلهای شبکه‌های عصبی در بر آورد ظرفیت اعتباری مشتریان از توان بالاتری برخوردار است.

کلید واژه‌ها: شبکه‌های عصبی، رگرسیون لجستیک، رگرسیون خطی و تخصیص اعتبار

## ۱ - مقدمه

سیستمهای بانکی در هر کشور یکی از مهمترین عوامل مؤثر بر رشد اقتصادی آن کشور محسوب می‌شود. نکته حائز اهمیت آن است که چگونه این سیستم می‌تواند به نحو مطلوبی عمل کند و توسعه اقتصادی را در یک کشور فراهم آورد. در پاسخ به این سؤال باید گفت که کارکرد صحیح این سیستم منوط به استفاده صحیح از منابع جمع‌آوری شده می‌باشد. در صورتی که سیستم بانکی بتواند منابع جمع‌آوری شده را به نحو مطلوبی تخصیص دهد،





قطعاً وظیفه اصلی خود را که کمک به رشد و توسعه اقتصادی است به نحو مطلوب انجام داده است. بنابراین، تخصیص منابع در سیستم بانکی به عنوان یکی از ارکان اساسی این سیستم محسوب خواهد شد. در این زمینه باید گفت که زمانی سیستم بانکی خواهد توانست به این وظیفه خود جامه عمل بپوشاند که منابع جمع‌آوری شده را به نحو مطلوبی در زمینه رشد و توسعه اقتصادی به کار گیرد و این امر مستلزم بررسی و ارزیابی صحیح دریافت‌کنندگان تسهیلات می‌باشد.

از دیگر سو آنچه حائز بیشترین اهمیت است این است که اگر بانکها بتوانند منابع جمع‌آوری شده را به نحو مطلوبی به دریافت‌کنندگان تسهیلات اعطا نمایند، نتیجه حاصل موجب برگشت صحیح منابع گشته، به تبع آن، موفقیت بانک در کوتاه‌مدت و بلندمدت تضمین خواهد شد. بنابراین ارزیابی صحیح دریافت‌کنندگان تسهیلات به صورت یک فرایند دو سویه، علاوه بر اثر غیر قابل انکار بر رشد و توسعه اقتصادی، در موفقیت بانکها نیز مؤثر است. ارزیابی صحیح مشتریان نیز در پاسخ به دو سؤال اساسی نهفته است:

- ۱) ریسک اعتباری مربوط به هر یک از دریافت‌کنندگان وام چقدر است؟
- ۲) ظرفیت اعتباری هر یک از دریافت‌کنندگان وام چقدر است؟

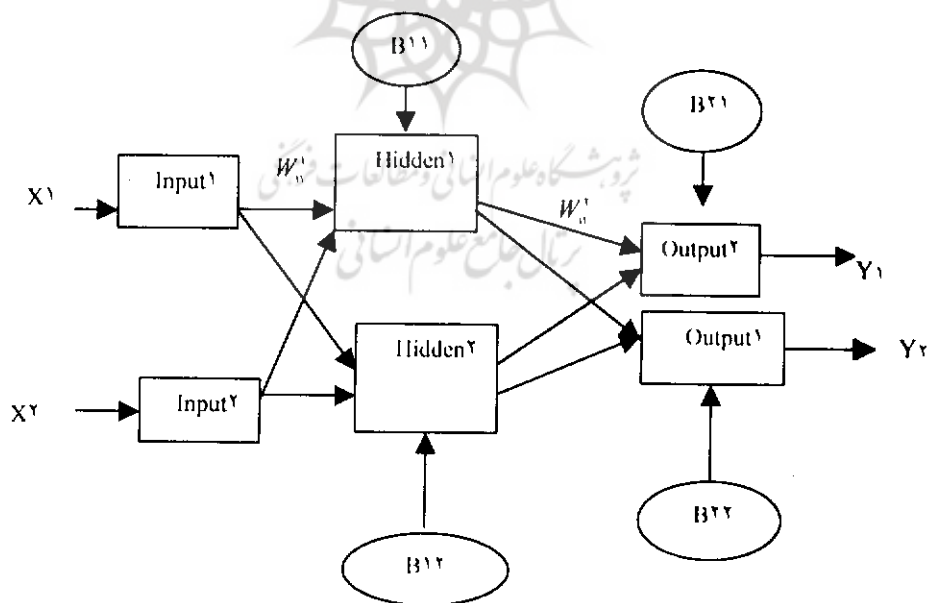
منظور از ریسک اعتباری همان احتمال عدم برگشت اصل وام اعطایی از سوی مشتریان می‌باشد. در این زمینه باید گفت که در برخی از مواد دریافت‌کنندگان وام توان ارزیابی منافع حاصل از سرمایه‌گذاری خود را ندارند و در نهایت امر متضرر می‌شوند و به تبع آن نمی‌توانند تسهیلات دریافتی را پرداخت نمایند. در مورد ظرفیت اعتباری - نیازهای واقعی افراد برای دریافت وام - نیز در غالب موارد میزان تسهیلات دریافتی توسط دریافت‌کنندگان تسهیلات، انطباق لازم را با ظرفیت اعتباری آنها ندارد. 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 می‌شود، لکن استفاده از این روش با توجه به توان محدود انسان در تحلیل همزمان فاکتورهای مختلف مؤثر بر ریسک و ظرفیت اعتباری دریافت‌کنندگان اعتبار در مقایسه با روشهای آماری و همچنین روشهای هوش مصنوعی از کارایی کمتری برخوردار است. [۴] در همین راستا در طی چند سال اخیر مدل‌های شبکه‌های عصبی جایگاه ویژه‌ای را در بازارهای مالی، ارزیابی داراییهای منقول و حتی در مراقبتهای بهداشتی به خود اختصاص داده است [۱ و ۲ و ۸ و ۱۷] لکن مدل‌های شبکه عصبی در مقایسه با برخی از مدل‌های کلاسیک مانند تحلیل ممیزی از اهمیت ویژه‌ای در بر آورد و تخمین



برخوردار هستند. [۷] این مدلها را می‌توان به نوعی تعمیمی از مدل‌های رگرسیون غیر خطی به شمار آورد. [۵] از این رو به کارگیری این مدلها از سوی محققین برای تشخیص روندها و الگوها در داده‌ها و همچنین تولید دانش از داده‌ها به صورت گسترده‌ای فراگیر شده است. [۶] انعطاف‌پذیری فوق‌العاده این مدلها نیز از عوامل دیگری است که سبب به کارگیری آنها در تمام زمینه‌های دانش به صورت فراگیر شده است. از این رو در این مقاله علاوه بر کاربرد شبکه‌های عصبی در تخصیص منابع و ارزیابی ریسک دریافت‌کنندگان وام، این مدل با مدل‌های رگرسیون لجستیک و خطی مقایسه شده است.

## ۲ - شبکه‌های عصبی

یکی از کاربردهای مدل‌های شبکه‌های عصبی، پیش‌بینی و تخمین یک متغیر ویژه با استناد به تعدادی ورودی می‌باشد [۷]: بدین معنی که مدل‌های شبکه‌های عصبی با استفاده از یک سری داده‌های ورودی داده خروجی را با استفاده از یک فرایند مشخص پیش‌بینی می‌کنند. مدل‌های شبکه عصبی یک سری داده ورودی و خروجی را گرفته، رابط بین متغیرهای ورودی و خروجی را مشابه مدل‌های رگرسیون غیر خطی تخمین می‌زنند. در این مدل، کل داده‌های مدل



شکل ۱ یک مدل شبکه عصبی پرسپترون چند لایه با ۲ ورودی و ۲ خروجی [۱۰]



به دو گروه آموزش<sup>۱</sup> و آزمایش<sup>۲</sup> تقسیم می‌شود و پس از آن کل داده‌های آزمایش از مدل حذف می‌شود و با استفاده از داده‌های آموزشی مدل مورد نظر برازش می‌گردد. پس از برازش مدل از داده‌های آزمایشی برای تست مدل استفاده می‌شود. غالباً حدود ۱۰ تا ۲۰ درصد از کل داده‌ها را به عنوان داده‌های آزمایشی تعریف می‌کنند [۸]، هر چند در برخی از مدل‌های شبکه عصبی حجم داده‌های آزمایشی تا ۲۵ درصد کل داده‌ها نیز می‌رسد. [۶] باید توجه داشت که در مدل‌های سری زمانی داده‌های آزمایشی باید از داده‌های اخیر انتخاب شود، ولی در مدل‌های معمولی، انتخاب داده‌های آزمایشی به صورت تصادفی صورت می‌گیرد. هدف اساسی از داده‌های آزمایشی آن است که با استفاده از آنها بتوان نتایج پیش‌بینی شده از طریق مدل را برای داده‌های آزمایشی با جواب واقعی آنها مقایسه نمود. بدیهی است اختلاف بین متغیر وابسته پیش‌بینی شده از طریق مدل و مقدار واقعی آن در داده‌های آزمایشی، نشان‌دهنده مقدار خطا خواهد بود که با استفاده از متوسط قدر مطلق خطا<sup>۳</sup> یا مجموع مربعات خطا<sup>۴</sup> نشان داده می‌شود. مجموعه داده‌های آزمایشی را در برخی موارد مجموعه داده‌های تولید<sup>۵</sup> نیز می‌نامند. [۸] شکل زیر یکی از مدل‌های معروف شبکه عصبی را که پرسپترون چند لایه نامیده می‌شود نشان می‌دهد:

چنانکه ملاحظه می‌شود این شبکه دارای یک لایه ورودی، یک لایه خروجی و یک لایه پنهان می‌باشد. در این مدل  $x_1$ ،  $x_2$  بردار ورودی و  $y_1$  و  $y_2$  بردار خروجی شبکه را نشان می‌دهد. پس این شبکه عصبی دارای ۲ متغیر ورودی و دو متغیر خروجی می‌باشد.  $w_{jk}$  در مدل فوق وزن متغیر  $k$ ام به نرون  $k$ ام در لایه  $k$ ام را نشان می‌دهد. به جز لایه ورودی، هر کدام از نرون‌های لایه پنهان در مدل فوق تابع تبدیل مربوط به نرون مربوط را نشان می‌دهد. بنابراین خروجی یکی از لایه‌های نرون پنهان به عنوان مثال به صورت زیر خواهد بود:

$$Y^H = g\left(\sum_{i=1}^Y w_{jk}^i x_j\right) + w_{jh}$$

- 1 - Training data
- 2 - Test data
- 3 - Absolute error
- 4 - Mean Squared error
- 5 - Product set



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

$$Y^O = \sum_{h=1}^I w'_{kj} (g(\sum_{j=1}^I w'_{jk} x_j) + w'_{jb}) + w'_{jh}, k = 1, 2$$

آنچه در یک مدل شبکه عصبی حائز اهمیت است آن است که وزنهای موجود در شبکه عصبی به نحو مطلوبی بر آورد شوند. بدیهی است پس از تعیین وزنها به نحو مطلوب با دادن بردار متغیرهای ورودی به سهولت می توان مقادیر بردار خروجی را بر آورد نمود. تعیین وزنها در شبکه عصبی از یک الگوریتم کارآمد پیروی می کند که در اینجا به عنوان الگوریتم یادگیری از آن یاد می کنیم.

### ۳- الگوریتم یادگیری در شبکه های عصبی

به منظور بر آورد مقادیر مطلوب بردار وزنها از روشهای متعددی استفاده می شود که مهمترین و پرکاربردترین آنها که اغلب در شبکه های عصبی پرسپترون چند لایه مورد استفاده قرار می گیرد، الگوریتم پس انتشار خطا<sup>۱</sup> می باشد. [۱۲] در این روش، همچنان که از عنوان آن بر می آید، مقدار خطا مجدداً به مدل شبکه های عصبی منتقل و مقادیر وزنها را تعدیل می نماید. [۹]

با توجه به موارد فوق، معادله مربوط به تعدیل وزنها را می توان تعریف نمود. بدین منظور فرض نماییم  $x_j^{[s]}$  نشان دهنده نرون  $j$  ام در لایه  $S$  و  $f(I_i^{[s]})$  نشان دهنده مجموع موزن ورودی نرون  $i$  ام در لایه  $S$  و  $e_k^{[s]}$  میزان خطای محلی<sup>۲</sup> نرون  $k$  ام در لایه  $S$  باشد. در این صورت، معادله بردار تغییر وزن به صورت زیر در می آید: [۱۱]

$$\Delta w_{ij}^{[s]} = \eta f(I_i^{[s]}) \sum_k (e_k^{[s+1]} w_{ki}) X_i^{[s-1]} + \theta \Delta w_{ij}$$

و برای لایه بدون خروجی، تابع یادگیری به صورت زیر خواهد بود:

$$\Delta w_{ij}^{[s]} = \eta (Y_i - O_i) \cdot f(I_i) X_i^{[s-1]} + \theta \Delta w_{ij}$$

برای لایه خروجی  $\eta$  نشانگر ضریب یادگیری و  $\theta$  بیانگر تکان لحظه ای<sup>۳</sup> است. استفاده از روابط ۱ و ۲ برای تعدیل وزنها، بستگی به نوع شبکه دارد. با توجه به اینکه در طبقه بندی

1 - Back Propagation error

2 - Local error

3 - Momentum Terms



شبکه‌های عصبی، آنها را به دو گروه شبکه‌های عصبی بدون ناظر و با ناظر تقسیم می‌کنند، زمانی که متغیر ورودی و هم متغیر خروجی برای مدل مشخص باشد، مدل مربوط به سهولت می‌تواند مقادیر خطا را تعیین و به تبع آن بردار وزنه‌های مدل را بهبود بخشد. در این زمینه می‌توان به مدل رگرسیون تعمیم‌یافته شبکه‌های عصبی اشاره نمود. برخی مواقع نیز مقادیر بردار ورودی مدل کاملاً مشخص می‌باشد، لکن بردار خروجی مدل در دست نیست.

به عنوان مثال، داده‌های مربوط به دسته‌بندی و بهینه‌سازی را در مدل‌های خطی و غیر خطی می‌توان در این طبقه جای داد. در یک مدل بهینه‌سازی، مقدار جواب بهینه در دسترس نمی‌باشد، اما مقادیر بهبود در هر تکرار دقیقاً قابل بررسی و ارزیابی می‌باشد؛ بدین معنی که اگر پس از هر تکرار جواب مدل بهبود یابد، این امر بدان معنی خواهد بود که مدل به سمت جواب بهینه حرکت می‌کند.

بنابراین حلقه یادگیری تا دستیابی به بردار وزن مطلوب ادامه خواهد یافت. از جمله راههایی که می‌تواند از توقف شبکه‌های عصبی در نقاط حداقل محلی<sup>۱</sup> جلوگیری کند، استفاده از داده‌های آموزشی تصادفی و انتخاب مقدار مطلوب به عنوان نرخ یادگیری<sup>۲</sup> می‌باشد. انتخاب نرخ یادگیری پایین، سرعت یادگیری را پایین می‌آورد، لکن از طرف دیگر، انتخاب نرخ یادگیری بزرگ ممکن است موجب واگرایی<sup>۳</sup> مدل گردد. هر چند انتخاب ضریب کوچک برای یادگیری موجب از بین رفتن نوسانات<sup>۴</sup> خواهد شد، ولی در برخی موارد نیز نرخ یادگیری را بزرگ انتخاب می‌کنند، لکن مقدار آن به تدریج کاهش می‌یابد تا اینکه مدل همگرا گردد.

آنچه در تمام فرایندهای تکراری حائز اهمیت است آن است که تکرار الگوریتم باید تا چه زمانی ادامه یابد. در این مورد باید گفت که سه راه برای توقف الگوریتم وجود دارد [۵]:

- ۱ - توقف پس از چند تکرار مشخص،
- ۲ - کاهش میزان خطا تا یک حد معین،
- ۳ - به وجود آمدن ثبات در شبکه عصبی، بدین معنی که پس از چند تکرار متوالی هیچ بهبودی در شبکه عصبی مشاهده نگردد.



1 - Local Minimum  
2 - Learning Rate  
3 - Divergent  
4 - Oscillation

#### ۴ - اندازه شبکه عصبی<sup>۱</sup>


سؤالات اساسی که همواره در طراحی شبکه‌های عصبی مطرح است آن است که اولاً تعداد نرونها (پردازشگرهای) مورد نیاز در یک شبکه معین باید چقدر باشد، و ثانیاً با فرض اینکه تعداد نرونها مشخص باشد، تعداد لایه پنهان را چگونه می‌توان تعیین نمود؟

در مورد سؤالات مطروح فوق هیچ جواب صریحی ارائه نشده است. در سال ۱۹۸۶ یک روش آماری برای انتخاب اندازه شبکه و تعداد نرونها تحت عنوان نگرش ممیزی<sup>۲</sup> پیشنهاد گردید [۱۳]، اما در نهایت یک الگوی عملیاتی در این زمینه ارائه نکرد. در سال ۱۹۹۳ نیز یک سری دستورالعملها ارائه گردید که معیاری برازش را بهینه می‌نمود. در اینجا نیز از همان دستورالعمل‌های آماری استفاده می‌شد [۱۴]. این دستورالعملها نیز در سال ۱۹۹۶ بشدت از سوی محققین رد گردید [۱۵]. از آن زمان تا کنون نیز در مورد توپولوژی شبکه‌های عصبی تکنیک‌های متعددی ارائه شده است که هیچ کدام از آنها دارای جامعیت لازم نمی‌باشد. از اینرو تا به حال در اغلب مدل‌های شبکه‌های عصبی استفاده شده برای انتخاب تعداد نرونها (پردازشگرها) و همچنین تعداد لایه‌های پنهان، از روشهای ابداعی استفاده می‌شود.

مبنای استفاده از نرونها بر این اصل استوار است که هر اندازه تعداد نرونها افزایش یابد انعطاف شبکه بیشتر خواهد شد، لکن انعطاف بیشتر در یک مدل شبکه عصبی مصنوعی همواره مطلوب نمی‌باشد، زیرا انعطاف بیش از حد مدل موجب برازش بیش از حد<sup>۳</sup> مدل خواهد شد. به عبارت دیگر، مدل در این صورت در فرایند یادگیری مقادیر خطا را نیز آموزش دیده و حساسیت مدل را برای تعمیم به داده‌های جدید کاهش می‌دهد. شکل ذیل نمونه‌ای از یک مدل بیش از حد برازش شده را نشان می‌دهد. [۹ و ۱۶]

در مورد تعداد لایه پنهان نیز اغلب یک لایه پنهان به تنهایی کافی می‌باشد، لکن در این صورت، سرعت یادگیری کاهش خواهد یافت. با افزودن لایه پنهان دوم، سرعت یادگیری تسریع می‌شود. برای تعیین تعداد نرونها اغلب مشابه مدل رگرسیون از روش گام به گام استفاده می‌شود. در روش رگرسیون گام به گام<sup>۴</sup> یک مدل با تعداد کمی از متغیرها شروع می‌کند و پس از آن، متغیرها مهم را یک به یک به مدل اضافه می‌نمایند. با یک مدل گام به گام ممکن است با کلیه متغیرهای موجود حل مسأله را شروع کند و پس از آن گام به گام متغیرهایی که اهمیت کمتری دارند را حذف نماید. همین استراتژی در مورد شبکه‌های عصبی نیز مصداق دارد.

1 - Size of Neural Network  
2 - Discriminating approach  
3 - Over fitting  
4 - Step by Step



شکل ۲. برازش بیش از حد یک مدل شبکه عصبی

به عنوان مثال، شبکه‌های همبستگی کاسکید با صفر نرون در لایه پنهان شروع و در هر زمان یک نرون به لایه پنهان اضافه می‌کند تا اینکه شاخص خطا ارضا شود و یا در برخی موارد با تعداد کمی نرون شروع می‌کند و به تدریج نرونهای زائد را حذف می‌نماید. در هر حال، نتایج حاصل از بررسیها حاکی از آن است که استفاده از شبکه‌های دارای نرونهای زیاد به جای استفاده از شبکه سختی که نرونهای ثابت دارند برای دستیابی به جواب خوب از کارایی بالاتری برخوردار هستند [۱۳]. در این مقاله از این روش برای تعیین تعداد نرونها در لایه پنهان استفاده شده است.

## ۵- رگرسیون لجستیک

یکی از مهمترین مدل‌های کلاسیک که اغلب برای پیش‌بینی مورد استفاده قرار می‌گیرد، مدل‌های رگرسیونی می‌باشد. در صورتی که متغیر وابسته به شکل ۰ یا ۱ باشد باید از مدل رگرسیون لجستیک استفاده شود. شکل کلی رگرسیون لجستیک به صورت زیر می‌باشد:

$$\pi(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}$$

زمانی که متغیر وابسته برابر یک باشد، انتظار داریم که  $\pi(x)$  به یک نزدیکتر شود و بالعکس. در این مقاله با توجه به اینکه ریسک اعتباری مشتریان به عنوان یک متغیر صفر و





یک تعریف شده، از مدل رگرسیون لجستیک استفاده شده است (یک برای مطالبات سر رسید گذشته و معوق و صفر برای مطالبات زنده). از طرف دیگر از آنجا که علاوه بر سنجش ریسک اعتباری مشتریان در صدد سنجش ظرفیت اعتباری آنان نیز بودیم، از رگرسیون خطی ساده نیز در مدل استفاده گردید. بنابراین در این روش پژوهش با دو متغیر وابسته سر و کار داریم که یکی از آنها باینری (صفر و یک) و دیگری پیوسته (ظرفیت اعتباری) است. بنابراین مدل رگرسیون کلی را می‌توان به صورت زیر تعریف نمود:

$$f(R, C) = \left( \frac{e^{\beta_1 x_1 + \beta_0}}{1 + e^{\beta_1 x_1 + \beta_0}}, \beta_1' x_1 + \beta_0' \right)$$

در این مدل، متغیر R ریسک اعتباری و متغیر C ظرفیت اعتباری مشتریان را نمایش می‌دهد. بنابراین همچنانکه ملاحظه می‌شود، متغیر وابسته ریسک همواره دارای مقدار بین صفر و یک خواهد بود و حالی که متغیر وابسته ظرفیت اعتباری همواره دارای مقداری پیوسته می‌باشد.

## ۶- متدولوژی تحقیق

در این پژوهش به منظور ارزیابی کارایی مدل‌های شبکه عصبی، ابتدا داده‌های پژوهش با استفاده از مدل‌های کلاسیک مورد بررسی قرار گرفت. بدین منظور پس از شناسایی مدل، تعدادی از متغیرهای اثرگذار بر ریسک اعتباری مشتریان شناسایی گردید و برخی از متغیرها که دارای اثر معنی‌داری بر متغیرهای وابسته نبودند، حذف شدند. بنابراین فقط متغیرهایی در مدل کلاسیک مورد استفاده قرار گرفت که اثر معنی‌داری بر هر دو متغیر وابسته داشتند. سپس با استفاده از همان متغیرها، مدل شبکه‌های عصبی طراحی گردید تا با در نظر گرفتن متغیرهای یکسان، کارایی دو مدل مورد بررسی و آزمون قرار گیرد. بدیهی است شناسایی متغیر پژوهشی در همگرایی مدل‌های شبکه عصبی مؤثر می‌باشد. باید توجه داشت که قبل از طراحی مدل، متغیرهای پژوهش به ندرت قابل بررسی و ارزیابی می‌باشند، بدین معنی که اهمیت متغیرهای مختلف از نظر اثرگذاری بر متغیر وابسته زمانی آشکار می‌شود که مدل مربوط طراحی و تدوین شده باشد. لذا در این مقاله ابتدا حدود ۵۰ متغیر به عنوان متغیرهای در دسترس در مورد مشتریان اعتباری مورد بررسی قرار گرفت و سپس از بین متغیرهای موجود ۱۱ متغیر به عنوان متغیرهای اثرگذار شناسایی و به عنوان متغیرهای برآوردکننده تعریف گردید که این متغیرها به شرح زیر است:




- ۱- نوع فعالیت شرکت (تولیدی، کشاورزی، ساختمانی، بازرگانی، خدماتی) - ۴ - X۱ و  
X۱-۳ و X۱-۲ و X۱-۱
- ۲- سابقه فعالیت مشتری - X۲
- ۳- سرمایه ثبت شده - X۳
- ۴- سابقه فعالیت مدیر شرکت - X۴
- ۵- جمع داراییهای جاری - X۵
- ۶- جمع داراییهای ثابت - X۶
- ۷- جمع کل داراییها - X۷
- ۸- جمع بدهیهای جاری - X۸
- ۹- جمع گردش بدهکار در نزد شعبه - X۹
- ۱۰- جمع گردش بستانکار در نزد شعبه - X۱۰
- ۱۱- نرخ بازده سرمایه - X۱۱

متغیرهای وابسته تحقیق نیز که با استفاده از متغیرهای برآوردکننده در صدد پیش‌بینی آن بودیم نیز به شرح زیر تعریف می‌شوند:

الف) ظرفیت اعتباری مشتریان - Y۱

ب) ریسک اعتباری مشتریان - Y۲

این متغیرها در مدل‌های رگرسیون به عنوان متغیرهای وابسته و در مدل شبکه عصبی به عنوان متغیرهای خروجی شبکه بیان می‌شوند. با توجه به اینکه اطلاعات موجود به صورت پایگاه اطلاعات کامپیوتری در دسترس نبود، به جمع‌آوری اطلاعات مربوط به هر مشتری - ۵۰ متغیر اولیه - به صورت دستی از هر کدام از شعب بانک اقدام گردید. بدین منظور ۴۳۰ نفر از مشتریان به صورت تصادفی انتخاب و مورد بررسی قرار گرفتند که پس از بررسی اولیه، اطلاعات مربوط به ۳۷۹ نفر از مشتریان برای طراحی مدل‌های کلاسیک و شبکه‌های عصبی مورد استفاده قرار گرفته و اطلاعات مربوط به آنها برای شناسایی متغیرهای اثرگذار و سپس برآورد پارامترهای مدل بهره‌برداری شد. از بین مشتریان انتخاب شده ۲۳۱ مشتری دارای مطالبات زنده و ۴۸ مشتری دارای مطالبات معوق و سر رسید گذشته بودند. پس از شناسایی متغیرها، به منظور بررسی و آزمایش کارایی دو مدل شبکه‌های عصبی و کلاسیک با همدیگر ۱۰ درصد نمونه آماری به عنوان داده‌های آزمایش در برآزش مدل مورد استفاده قرار گرفت تا با استفاده از پارامترهای مدل، متغیر وابسته این گروه هم از طریق شبکه‌های



عصبی و هم از طریق مدل کلاسیک برآورد و با جوابهای واقعی مقایسه گردد. بدیهی است که میزان انحراف هر دو مدل از نتایج واقعی می‌تواند معیار مناسبی برای ارزیابی کارایی دو مدل باشد. از آنجا که اتکا به یک گروه از داده‌ها برای نتیجه‌گیری در این زمینه کافی به نظر نمی‌رسد در اینجا با استفاده از نمونه‌گیری سیستماتیک و با جایگذاری، سه گروه داده آزمایش انتخاب و مدل شبکه‌های عصبی و کلاسیک در هر سه گروه طراحی و مورد ارزیابی و سنجش قرار گرفت. بنابراین فقط در هر سه گروه اطلاعات مربوط به ۲۴۱ نفر از مشتریان برای برآزش مدل مورد استفاده قرار گرفت و ۲۸ نفر از مشتریان به عنوان داده‌های آزمایش کنار گذاشته شدند.

## ۷- تحلیل داده‌ها و طراحی مدل

با توجه به اینکه برآورد پارامترهای در مدل‌های رگرسیون لجستیک و شبکه‌های عصبی با استفاده از روشهای تکرار امکان‌پذیر است، برای تحلیل داده‌ها و برآورد مدل از نرم‌افزارهای کامپیوتری مربوط استفاده گردید. در این پژوهش برای طراحی مدل شبکه‌های عصبی و برآورد پارامترهای مدل از نرم‌افزار Statistica Neural Network و برای برآورد پارامترهای مدل در مدل کلاسیک از نرم‌افزار SPSS استفاده گردید. بنابراین پارامترهای مدل (ضرایب هر کدام از متغیرهای مستقل در مدل رگرسیون خطی و لجستیک به همراه وزنهای هر کدام از ورودیهای هر نرون در شبکه‌های عصبی) برای هر گروه با استفاده از داده‌های آموزشی برآورد شد و با استفاده از داده‌های آزمایش مورد آزمایش قرار گرفت. با توجه به حجم مدلها در اینجا فقط مدل‌های کلاسیک و شبکه‌های عصبی مربوط به یکی از گروه‌ها ذکر شده است.

### ۱- مدل رگرسیون خطی

برای تعیین ظرفیت اعتباری مشتریان اعتباری از رگرسیون خطی استفاده گردید. رابطه زیر مدل رگرسیون خطی مربوط را نشان می‌دهد:

$$Y_1 = -980/1896X_{1-1} - 611/688X_{1-2} + 297/195X_{1-3} + 286/761X_{1-4} + 9/141X_{1-5} - 0/115X_{1-6} + 12/219X_{1-7} + 0/167X_{1-8} - 0/0002X_{1-9} - 0/05X_{1-10} - 0/051X_{1-11} - 0/086X_{1-12} - 0/268X_{1-13} + 1689/96X_{1-14} + 1194/132$$



در این مدل  $Y_1$  بیانگر ظرفیت اعتباری مشتریان و  $X$ ها متغیرهای مستقل بیان شده در متدولوژی تحقیق را نشان می‌دهد.

## ۲- مدل رگرسیون لجستیک

مدل رگرسیون لجستیک که برای سنجش و برآورد ریسک اعتباری مشتریان مورد استفاده قرار گرفت به صورت زیر می‌باشد:

$$Y_1 = \ln\left(\frac{P}{1-P}\right) = 1/1333x_{1-1} - 1/5792x_{1-2} - 0/9657x_{1-3} + 1/034x_{1-4} - 0/273x_2 - 0/0003x_3 - 0/2446x_4 - 0/00005x_5 - 0/0001x_6 - 0/000006x_7 - 0/00002x_8 - 0/0009x_9 - 0/0017x_{10} - 7/8476x_{11} + 4/92099$$

در این مدل  $P$  ریسک اعتباری مشتریان را نشان می‌دهد. بنابراین تابع  $P$  به صورت رابطه زیر خواهد بود.

$$p = \pi(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}$$

در این مدل هر اندازه  $P$  به یک نزدیکتر باشد، ریسک اعتباری بیشتر و به بیان دیگر احتمال عدم بازگشت تسهیلات بیشتر می‌باشد.


## ۳- مدل شبکه‌های عصبی

با توجه به قابلیت‌های مدل شبکه‌های عصبی در برآورد همزمان یک یا چند متغیر، از این مدل برآورد همزمان دو متغیر وابسته ریسک اعتباری و ظرفیت اعتباری استفاده گردید. مدل شبکه‌های عصبی که برای این منظور مورد استفاده قرار گرفت، شبکه عصبی پرسپترون سه لایه با یک لایه پنهان می‌باشد.

شکل ۲ مدل مربوط را نشان می‌دهد:

همچنانکه از شکل فوق مستفاد می‌شود شبکه برآزش شده دارای شش نرون در لایه پنهان و دو نرون در لایه خروجی می‌باشد. در این شبکه، توابع فعال استفاده شده در لایه پنهان لجستیک می‌باشد.





شکل ۳ شبکه عصبی برآزش شده برای داده‌های آزمایش گروه ۱

جدول ۱ بردار وزنه‌های متغیر بایاس و متغیرهای ورودی در لایه اول

متغیر بایاس و متغیرهای ورودی	H <sub>1</sub> -۰۱	H <sub>1</sub> -۰۲	H <sub>1</sub> -۰۳	H <sub>1</sub> -۰۴	H <sub>1</sub> -۰۵	H <sub>1</sub> -۰۶
Bias	-۲/۶۸۲	-۸/۸	-۰/۴۲۵۹	-۲/۰۹۲	-۷/۵۷۷	-۱/۴۸۵
X <sub>1</sub> -۱	-۰/۴۵۹۱	۰/۹۴۵۵	-۱/۰۹۱	۲/۸۸۸	۲/۱۲۶	۰/۶۳
X <sub>1</sub> -۲	۰/۳۵۰۵	-۰/۲۷۸۱	-۱/۹۱۵	-۱/۲۰۳	-۰/۳۵۷۹	-۰/۱۹۸۵
X <sub>1</sub> -۳	۱/۰۹۶	-۰/۵۲۶۸	-۲/۳۲۶	-۰/۱۶۸۳	-۱/۰۶۸	-۰/۱۹۴۴
X <sub>1</sub> -۴	۲/۰۵۸	-۰/۱۷۶۱	-۱/۴۶۹	-۲/۰۰۲	-۰/۱۹۴۷	۱/۲۴
X <sub>2</sub>	-۲/۸۱	۲/۳۳۵	۹/۳۵۵	-۰/۸۵۷۸	۱/۴۱۴	۲/۳۷
X <sub>3</sub>	۰/۲۵۷۹	-۰/۵۷۵۲	-۰/۱۶۸۳	-۰/۱۶۱۱	-۱/۴۴۵	۱/۰۱۷
X <sub>4</sub>	-۰/۸۱۲۵	-۲۹/۰۳	-۱/۴۵۳	۱/۵۰۲	۶/۰۶۱	-۰/۷۵۷
X <sub>5</sub>	-۲/۹۳۶	-۲/۲۵۶	۰/۵۴۴۴	-۱/۵۶۲	-۱/۳۱۱	۱/۶۳۹
X <sub>6</sub>	۰/۹۸۸۷	-۰/۹۶۹۷	۱/۶۷۳	-۰/۸۲۶۶	۰/۶۲	۰/۱۷۶۸
X <sub>7</sub>	-۱/۹۲۹	۷/۴۸۵	۰/۸۲۱۴	-۲/۰۶۹	-۲/۹۹۵	۰/۴۴۶۶
X <sub>8</sub>	۰/۶۴۷۳	-۱/۲۸۷	۶/۰۲۲	-۱/۰۷	-۲/۵۲۴	۱/۶۲۲
X <sub>9</sub>	-۰/۳۱۷۴	-۸/۱۰۳	۷/۸۲۳	-۱/۵۳۷	-۶/۹۶۷	۱/۲۵۱
X <sub>10</sub>	-۰/۱۴۹۷	-۲/۱۳۸	۰/۵۳۲۹	-۰/۱۰۰۹۲۸	-۴/۲۵	-۰/۲۲۰۲

جدول فوق و جدول زیر بردار وزنها را در لایه‌های مختلف به همراه وزن متغیرهای بایاس نشان می‌دهد.

جدول زیر، ضریب هر کدام از نرونهای لایه پنهان را برای هر یک از متغیرهای خروجی

نشان می‌دهد.




جدول ۲ بردار وزنه‌های متغیر بایاس و نرونهای لایه پنهان

Y2	Y1	متغیر بایاس و نرونهای لایه پنهان
۳/۰۶۶	-۰/۲۱۱۸	BIAS
۲/۸۷۹	-۴/۲۷۸	h <sub>۱-۰۱</sub>
۱۴/۳۶	-۱/۵۱۴	h <sub>۱-۰۲</sub>
-۸/۸۳۱	-۰/۳۱۵۴	h <sub>۱-۰۳</sub>
۲/۴۶۸	-۲/۸۲۳	h <sub>۱-۰۴</sub>
۱۷/۱۱	-۰/۲۸۰۱	h <sub>۱-۰۵</sub>
-۴/۴۱۷	۱/۰۲	h <sub>۱-۰۶</sub>

### ۸- بررسی و مقایسه مدل‌های کلاسیک و شبکه عصبی


ارزیابی مدل‌های شبکه‌های عصبی و مدل‌های کلاسیک زمانی میسر است که با استفاده از پارامترهای برآورد شده و بردار متغیرهای ورودی، مقادیر متغیرهای وابسته برای یک سری رکوردهای جدید (متشریانی که اطلاعات آنها در برازش مدل استفاده نشده است) محاسبه و با مقدار واقعی مقایسه شود تا اینکه مقدار خطا تعیین گردد. بدیهی است هر کدام از مدل‌ها که خطای کمتری داشته باشد از کارایی مطلوبتری برخوردار خواهد بود. بدین منظور با استفاده از پارامترهای مدل‌های کلاسیک و شبکه‌های عصبی، متغیرهای وابسته هر سه گروه از داده‌های آزمایش که کاملاً با همدیگر متفاوت بودند برآورد و با مقادیر واقعی مقایسه گردید که نتایج حاصل از مقایسه در جدول ذیل آورده شده است.

جدول ۳ ظرفیت اعتباری و ریسک اعتباری مشتریان را بر اساس مدل‌های کلاسیک و شبکه‌های عصبی نشان می‌دهد. در این جدول، مقادیر واقعی تسهیلات دریافتی مشتریان به همراه برآوردهای حاصل از شبکه‌های عصبی و رگرسیون خطی آورده شده است. مشاهده سه ستون اول مربوط به این موضوع، بیانگر خطای کمتر شبکه‌های عصبی نسبت به مدل کلاسیک می‌باشد. نمودار ۱ و ۲ بوضوح قابلیت بیشتر شبکه‌های عصبی را نسبت به مدل رگرسیون خطی نشان می‌دهد؛ در این نمودار، همچنانکه ملاحظه می‌شود، شیب نمودار شبکه عصبی و رگرسیون خطی تقریباً مشابه همدیگر و نزدیک یک است. البته با توجه به اینکه نمودارهای فوق، رابطه بین داده‌های واقعی و پیش‌بینی شده را نشان می‌دهد، هر اندازه ضریب مربوط به یک نزدیکتر شود، بیانگر قابلیت بیشتر مدل خواهد بود. لکن ضریب تشخیص برای نمودار رگرسیونی برابر ۰/۱۴ است، در حالی که این ضریب برای شبکه‌های عصبی برای ۰/۸۲ است که نشانگر توانایی بسیار زیاد شبکه‌های عصبی در پیش‌بینی ظرفیت




جدول ۳ مقایسه نتایج برآورد شبکه‌های عصبی و مدل‌های رگرسیون خطی و لجستیک با مقادیری واقعی (گروه آزمایش ۱)


ریسک اعتباری		ظرفیت اعتباری				ردیف
رگرسیون لجستیک	شبکه‌ها عصبی	داده‌های واقعی	رگرسیون خطی	شبکه‌ها عصبی	داده‌های واقعی	
۰	Right	۰۰	۷۷۰۶/۵۷۲	۷۶۵۰	۶۴۰۰	۱
۱	Wrong	۰۰	۲۴۲۹/۲۱۲	۵۴۰	۴۵۰/۷	۲
۰	Wrong	۰۰	۱۷۰/۹۲۵۴	۲۴۲۲	۲۸۴۰	۳
۰	Right	۰۰	۴۲۲۴/۰۷	۱۹۵۰	۳۱۰۰	۴
۰	Right	۰۰	۵۰۹۸/۰۶۴	۲۸۳۱	۳۹۷۰	۵
۰	Right	۰۰	۱۵۱۷۳/۸۱	۴۱۰۰	۴۹۰۰	۶
۰	Right	۰۰	۲۴۱۹/۴۲۱	۲۹۷۰	۲۷۷۰	۷
-	?	۰۰	۸۸۴/۰۹۴۵	۵۱۵۰	۵۱۵۰	۸
-	?	۰۰	۳۷۱۴/۳۷	۵۱۶۰	۶۱۷۰	۹
۰	Right	۰۰	۷۰۰۹/۲۳۸	۱۸۸۰	۱۴۲۰	۱۰
۰	Right	۰۰	۴۶۵۷/۵۰۶	۱۹۸۰	۲۱۷۰	۱۱
۰	Right	۰۰	۲۶۹۳/۳۱۹	۲۳۸۰	۲۹۰۰	۱۲
-	?	۰۰	۹۸۰۰	۱۴۸۰	۱۸۹۰	۱۳
۱	Right	۰۰	۱۲۲۴/۸۵۲	۲۲۹۰	۲۵۶۰	۱۴
۱	?	۰۰	۴۲۲۰/۴۷	۲۹۶۰	۲۴۲۰	۱۵
۰	Right	۰۰	۶۲۲۲/۰۱۲	۱۴۶۰	۱۳۲۰	۱۶
۰	Right	۰۰	۵۰۹۰/۲۳۳	۲۳۰۰	۱۸۹۰	۱۷
۰	?	۰۰	۶۶۰۰	۳۰۶۰	۳۶۹۰	۱۸
۰	Right	۰۰	۱۱۰۰۰	۴۲۲۰	۴۲۲۰	۱۹
۰	Right	۰۰	۵۲۰۰	۴۰۴۰	۵۵۲۰	۲۰
۰	?	۰۰	۲۲۲۹/۷۶۱	۲۳۸۰	۳۵۲۰	۲۱
-	?	۰۰	۲۲۱۴/۹۵۴	۲۹۸۰	۳۹۷۰	۲۲
-	Right	۰۰	۳۱۶۸/۰۸۴	۴۶۷۰	۵۲۲۰	۲۳
۱	Right	۱/۰۰	۹۳۲۰/۷۹۴	۶۰۰	۵۶۰	۲۴
۱	Right	۱/۰۰	۶۹۰۰	۱۵۰۰	۲۳۲۰	۲۵
۱	Right	۱/۰۰	۲۸۸/۱۹۴۹	۱۰۳۰	۱۰۵۰	۲۶
۱	Right	۱/۰۰	۲۳۵/۴۰۴۲	۲۹۰	۱۰۵۰	۲۷
۱	Wrong	۱/۰۰	۲۲۸۸/۱۹۵	۲۰۰۰	۴۲۸۰	۲۸
-	Right	۱/۰۰	۹۸۲/۳۱۳۵	۱۰۵۰	۱۱۵۰	۲۹
-	Right	۱/۰۰	۸۷۰۰	۳۵۰	۱۵۸۰	۳۰
۱	?	۱/۰۰	۶۲۰/۹۳۴۹	۱۵۰	۲۹۰	۳۱
-	Right	۱/۰۰	۱۲۷۱/۳۵۵	۲۴۱۰	۴۴۱۰	۳۲
-	Right	۱/۰۰	۱۴۰۱/۲۷۲	۴۲۹۰	۷۰۷۰	۳۳
-	Right	۱/۰۰	۸۴۹/۳۹۸	۵۸۰	۱۱۸۰	۳۴
۱	Right	۱/۰۰	۹۶۰۰	۱۰۵۰	۱۰۷۰	۳۵
۱	Right	۱/۰۰	۱۳۶۷/۸۴۲	۲۲۴۰	۱۸۵۰	۳۶
۱	Right	۱/۰۰	۱۶۳۶/۲۲۳	۱۱۳۰	۱۶۴۰	۳۷
-	Right	۱/۰۰	۴۹۰۸/۵۸۲	۲۵۳۰	۳۴۱۰	۳۸
۲۸	۲۹	—	—	—	—	درست
۱۰	۲	—	—	—	—	نادرست
—	۶	—	—	—	—	ناشناخته
۷۳/۶	۷۶/۳	—	—	—	—	درصد برآورد صحیح



نمودار ۱ ارتباط بین داده‌های مشاهده و پیش‌بینی شده با استفاده از رگرسیون خطی (گروه آزمایش ۱)



نمودار ۲ ارتباط بین داده‌های مشاهده شده و پیش‌بینی شده با استفاده از شبکه‌های عصبی (گروه آزمایش ۱)



نمودار ۳ ارتباط بین داده‌های مشاهده شده و پیش‌بینی شده با استفاده از رگرسیون خطی (گروه آزمایش ۲)






جدول ۴ مقایسه برآورد شبکه‌های عصبی و مدل‌های رگرسیون خطی و لجستیک با مقادیری واقعی (گروه آزمایش ۲)

ردیف	ظرفیت اعتباری			ریسک اعتباری	
	داده‌های واقعی	شبکه‌ها عصبی	رگرسیون خطی	داده‌های واقعی	شبکه‌ها عصبی
۱	۱۲۰۰	۱۱۳۰	۲۲۷۸/۰۰۹	...	Right
۲	۴۰۷۰	۲۸۷۰	۲۰۳۹/۶۲۵	...	Right
۳	۱۵۲۰	۱۲۵۰	۲۴۲۵/۸۴۹	...	Right
۴	۲۹۶۰	۲۶۹۷	۴۸۷۵/۴۲۸	...	Right
۵	۳۰۴۰	۲۳۵۰	۴۶۰۰/۰۷۳	...	?
۶	۴۸۱۰	۴۸۰۰	۵۹۶۱/۴۸۱	...	Right
۷	۳۵۷۰	۳۳۵۶	۲۴۱۷/۲۲	...	Right
۸	۱۰۰	۱۱۳۰	۱۳۲۲/۲۴۱	...	Right
۹	۲۷۲۰	۱۸۰۰	۲۴۱۱/۳۵۶	...	Right
۱۰	۲۸۲۰	۲۴۰۰	۱۷۸۸/۶۲	...	Right
۱۱	۴۲۰۰	۳۱۵۰	۴۳۱۴/۶۰۲	...	Right
۱۲	۳۳۰۰	۲۸۷۰	۴۶۰۵/۶۲۷	...	Right
۱۳	۱۶۹۰	۹۴۰	۱۹۶۵/۲۵۹	...	Right
۱۴	۲۱۹۰	۱۷۷۰	۱۳۹۵/۴۶۵	...	Right
۱۵	۴۸۶۰	۳۷۷۰	۷۱۸۶/۷۲۴	...	Right
۱۶	۲۴۰۰	۲۷۴۰	۲۴۸۵/۲۲۵	...	Right
۱۷	۵۰۴۰	۳۹۲۰	۲۰۳۶/۴۶۸	...	Right
۱۸	۳۹۸۰	۳۳۲۰	۳۶۰۰	...	Right
۱۹	۴۸۴۰	۴۲۰۰	۵۱۲۷/۰۲۲	...	Right
۲۰	۵۵۰۰	۶۵۰۰	۴۴۲۹/۳۹۲	...	Right
۲۱	۲۳۰۰	۲۱۶۷	۱۷۰۰	...	Right
۲۲	۲۵۱۰	۱۴۲۰	۲۲۰۵/۱۲۴	...	?
۲۳	۱۷۴۰	۱۸۷۰	۱۹۲۴/۱۷۸	...	Right
۲۴	۲۰۹۰	۱۳۹۰	۵۱۲/۱۶۶۹	۱/۰۰	?
۲۵	۲۶۲۰	۲۰۹۳	۱۰۶۲/۵۲۸	۱/۰۰	Right
۲۶	۱۷۰۰	۱۶۰۰	۴۹۹/۵۴۳۱	۱/۰۰	Right
۲۷	۲۰۵۰	۲۱۶۰	۶۰۲/۰۰۱۹	۱/۰۰	Right
۲۸	۱۱۳۰	۲۱۳۰	۲۳۵۴/۲۳۷	۱/۰۰	Wrong
۲۹	۲۱۷۰	۱۶۲۵	۶۳۳/۳۱۳۴	۱/۰۰	Right
۳۰	۸۹۰	۴۸۰	۱۱۲۹/۷۵۲	۱/۰۰	Right
۳۱	۴۶۷۰	۳۷۵۰	۱۱۳۰/۷۹	۱/۰۰	Right
۳۲	۲۳۷۰	۱۶۵۰	۱۱۴۶/۷۷۷	۱/۰۰	Right
۳۳	۱۶۶۰	۲۸۰۰	۱۳۸۴/۳۸۶	۱/۰۰	Right
۳۴	۷۲۰	۱۳۲۰	۱۶۵۲/۴۴۴	۱/۰۰	?
۳۵	۴۴۹۰	۴۴۳۰	۳۱۰۱/۷۱۶	۱/۰۰	?
۳۶	۲۹۲۰	۱۵۲۰	۱۳۱۵/۱۸۲	۱/۰۰	Right
۳۷	۱۹۵۰	۲۱۶۰	۱۳۳۳/۲۱۹	۱/۰۰	Right
۳۸	۱۴۵۰	۱۸۷۰	۲۰۷۷/۱۴۷	۱/۰۰	?
درست	—	—	—	—	۲۲
نادرست	—	—	—	—	۶
ناشناخته	—	—	—	—	۵
درصد برآورد صحیح					
	۸۴/۲	۸۱/۵			

اعتباری در مقابل مدل رگرسیون خطی می‌باشد. اما در مورد ریسک اعتباری که با استفاده از مدل رگرسیون لجستیک و شبکه‌های عصبی برآورد شده است باید گفت که هر دو مدل




تقریباً از قابلیت مشابهی برخوردار هستند. در هر حال در جدول فوق شبکه‌های عصبی ۷۶/۳ و مدل رگرسیون لجستیک ۷۳/۶ درصد از مشاهدات را منطبق بر واقع برآورد کرده‌اند. هر چند در اینجا اختلاف فاحشی بین دو مدل مشاهده نمی‌شود، لکن شبکه‌های عصبی فقط ۵ درصد از مشاهدات را نادرست برآورد و ۱۹ درصد باقیمانده را به صورت غیر قابل تشخیص (ناشناخته) گزارش کرده است. ستون ریسک اعتباری مشتریان در جدول فوق بوضوح این موضوع را نشان می‌دهد. اطلاعات مربوط به دو گروه دیگر نیز همانطور که از جدول ۴ و ۵ ملاحظه می‌گردد، اطلاعات مشابهی را نشان می‌دهد.




نمودار ۴ ارتباط بین داده‌های مشاهده‌شده و پیش‌بینی‌شده با استفاده از شبکه‌های عصبی (گروه

آزمایش ۲)



نمودار ۵ ارتباط بین داده‌های مشاهده‌شده و پیش‌بینی‌شده با استفاده از شبکه‌های عصبی (گروه


آزمایش ۳)



جدول ۵ مقایسه برآورد شبکه‌های عصبی و مدل‌های رگرسیون خطی و لجستیک با مقادیری واقعی (گروه آزمایش ۳)

ردیف	ظرفیت اعتباری			ریسک اعتباری	
	داده‌های واقعی	شبکه‌ها عصبی	رگرسیون خطی	داده‌های واقعی	شبکه‌ها عصبی
۱	۱۰۶۰	۵۵۰	۲۷۴۰	۰۰	Wrong
۲	۱۶۰۰	۱۷۲۰	۲۲۲۴	۰۰	Right
۳	۲۲۰۰	۱۷۶۷	۲۹۰۰	۰۰	?
۴	۵۹۴۰	۴۰۲۰	۱۸۵۸/۴۷	۰۰	Right
۵	۳۱۹/۷	۸۰۰	۲۲۶۳/۰۴	۰۰	Right
۶	۳۸۸۰	۲۶۴۰	۱۲۲۰	۰۰	Wrong
۷	۴۵۰۰	۳۱۵۹	۴۱۸۱/۸۵	۰۰	Right
۸	۳۵۳۰	۳۳۷۸	۳۵۵۴/۸۳	۰۰	Right
۹	۲۳۶۰	۲۲۶۰	۱۹۴۰/۷۶	۰۰	Right
۱۰	۵۳۷۰	۴۲۰۰	۹۳۰	۰۰	?
۱۱	۹۹۶/۸	۲۳۵۰	۲۸۲۱/۲۹	۰۰	?
۱۲	۵۴۳۰	۲۹۵۰	۳۲۱۰	۰۰	Right
۱۳	۱۱۸۰	۲۰۶۰	۲۲۰۸/۲۴	۰۰	Right
۱۴	۸۳۰	۲۰۰۰	۲۷۰۰/۳	۰۰	Right
۱۵	۱۸۶۰	۲۸۹۰	۳۴۰۰	۰۰	Right
۱۶	۱۷۵۰	۵۱۳۷	۱۳۶۲/۴۶	۰۰	?
۱۷	۲۱۳۰	۳۳۰۰	۴۰۴۶/۱۵	۰۰	Right
۱۸	۳۸۷۰	۴۳۵۰	۳۴۰۰	۰۰	Right
۱۹	۶۴۹۰	۵۶۰۰	۲۹۰۰	۰۰	Right
۲۰	۴۲۱۰	۴۸۰۰	۳۱۸۸/۳۱	۰۰	Right
۲۱	۲۷۲۵	۲۹۳۰	۳۰۰۰	۰۰	Right
۲۲	۲۳۰۰	۱۱۵۰	۳۳۸۰	۰۰	Right
۲۳	۲۸۰۰	۳۱۱۰	۲۹۴۴/۸۴	۰۰	?
۲۴	۱۴۵۰	۱۳۱۱	۱۵۳۳/۸۷	۱/۰۰	Right
۲۵	۱۶۶۰	۲۱۹۸	۱۳۳۸/۰۵	۱/۰۰	Right
۲۶	۱۹۷۰	۲۴۰۰	۲۰۶۲/۸۳	۱/۰۰	Right
۲۷	۲۰۰۰	۱۹۶۴	۱۱۰۷/۱۸	۱/۰۰	Right
۲۸	۱۲۱۰	۳۸۲۰	۱۷۴۷/۸۴	۱/۰۰	Right
۲۹	۴۰۲۰	۳۰۵۰	۷۱۸/۸۰۳	۱/۰۰	Right
۳۰	۵۰۴۰	۳۵۷۰	۳۱۰۲/۵۶	۱/۰۰	Right
۳۱	۳۸۶/۸	۱۴۹۶	۳۱۴۰	۱/۰۰	Right
۳۲	۳۸۳۰	۳۲۰۰	۱۰۵۰/۳۴	۱/۰۰	Right
۳۳	۵۶۲۰	۴۶۷۰	۱۴۳۰	۱/۰۰	Right
۳۴	۱۳۰	۱۱۴۵	۲۶۶۳/۲۱	۱/۰۰	Right
۳۵	۱۵۳۹	۳۰۰۰	۳۵۸۱/۱۳	۱/۰۰	Right
۳۶	۳۴۱۰	۳۷۳۰	۳۶۴۰	۱/۰۰	?
۳۷	۲۷۶۰	۲۰۰۰	۱۱۷۶/۰۱	۱/۰۰	Right
درست	—	—	—	—	—
نادرست	—	—	—	—	—
ناشناخته	—	—	—	—	—
۷۸/۳	۷۸/۳	—	—	—	—

درصد برآورد صحیح



نمودار ۶ ارتباط بین داده‌های مشاهده‌شده و پیش‌بینی‌شده با استفاده از شبکه‌های عصبی (گروه آزمایش ۳)

## ۹ - نتیجه‌گیری

با توجه به اهمیت تخصیص صحیح اعتبار در بانکها در این مقاله سعی گردید یک مدل ریاضی برای این منظور طراحی گردد. بدین منظور، مدل شبکه‌های عصبی و کلاسیک مورد استفاده قرار گرفت تا کاراترین آنها برای دستیابی به این هدف شناسایی گردد. بنابراین به منظور شناسایی مدل کارآمد، از مدل رگرسیون خطی برای برآورد ظرفیت اعتباری و از مدل رگرسیون لجستیک برای برآورد ریسک اعتباری و سپس از مدل شبکه‌های عصبی برای برآورد همزمان دو متغیر با توجه به قابلیت این مدلها استفاده گردید. نتایج حاصل از بررسی نشان داد شبکه‌های عصبی در برآورد متغیر باینری (۰ یا ۱) مشابه مدل رگرسیون لجستیک عمل می‌کنند، لکن در مورد برآورد ظرفیت اعتباری، مدل برازش‌شده شبکه‌های عصبی بسیار کارتر است، به گونه‌ای که در هر سه مدل برآورد شده، مدل شبکه‌های عصبی علاوه بر شیب مناسبتر نسبت به مدل رگرسیون خطی، از ضریب تشخیص بسیار بالایی نیز برخوردار بود. از این رو می‌توان گفت مدل شبکه‌های عصبی پرسپترون چند لایه در برآورد متغیرهای پیوسته کارتر از مدل‌های رگرسیون خطی معمولی عمل می‌نماید. در هر حال با توجه به این که این مدلها از فرایند جعبه سیاه استفاده می‌نمایند پیشنهاد می‌شود قبل از استفاده از این مدلها، مدل مربوط با استفاده از داده‌های آزمایش بدقت تست گردد.

## ۱۰ - منابع

- [1] Lowe, D., "Novel explanation of Neural network methods in financial markets", IEEE, Transactions on Networks, 3623 - 3628, 1994.



- [2] Worzala, E., Lenk, M. & Silvia, A., "An exploration of Neural Networks and its application to real state valuation", Journal of Real State Research, 10(2). 1995, 185-201
- [3] Buchmen, TG., Kubos, K.L, Seidler, A.J.& Siog forth, M.J., "A Comparison of Statistical and Connectionist models for the prediction of Chronicity in a Surgical intensive Care unit.", Journal of Critical Care Medicine, 22(5), 1994, 750-762
- [4] Bernnan, P.J, "Promise of Artificial Intelligence Remains elusive in Banking today", Bank Management, 1993, 49 – 53
- [5] Mcmenmin, J.s, "A primer on neural network for forecasting", Journal of Business Forecasting, 16(3), 1997 , 17 – 22
- [6] Liao, T.F, "A modified GMDH approach for Social Science research: exploring Patterns of relationships in the data", Quality and Quantity, 26, 192, 19-38
- [7] John C. B. Cooper, "Artificial neural network versus Multivariate statistics: an application from economics", journal of applied statistics, vol.26: 8: 1999: 909-921
- [8] Ward System Group (WSG), "Neuroshell 2. Users Guid", Frederick, MD, 1995, P. 101.
- [9] Back, B. & Back, R. J. R, "Financial Statement Planning in the Presence of Tax Constraints.
- [10] David, West, "Nerural Network Credits Scoring Models", Computer & Operations Research, 27, 2000, PP.1181 – 52.
- [11] Hayking, s., "Neural Network: A Comperehensive Fundation, Macmilan, New York, 1994, PP. 144-152.
- [12] Cudill, M. (ED), "Using Neural Networks: AI Expert", 1995.
- [13] Rumelhart, D.E, Hintom, G. E & Williams, R. J., "Learning internal Representation by error Propagation", in Rughart, D.E. (Ed) Parallel Distributed Processing, Vol. 1, PP. 818-62



- [14] Refenes, A.N, Zapranis, A. D. and Francis, G., "Neural Network Applications in Financial asset management", Journal of Neural Computing Applications 1993, Vol.1No.1.
- [15] Swinger, K., "Financial Prediction: Some Pointer and Common errors", Neural Computing and Applications. Vol.4, Springer – Verlag, 1996, London.
- [16] Fahlman, S. E., and lebierre, C., "The Cascade Correlation Learning Architecture", School of Computer Science Report CMU – Cs – 90–100, Carrengie Mellon university. 1990.
- [17] Altman EI., "Corporate distress Diagnosis: Comparisons using discriminant analysis and neural network (The Italian Experience). Journal of Banking and Finance 1994: 18: 505 – 29

