


## برآورد ریسک و ظرفیت اعتباری مشتریان بانک تجارت با استفاده از شبکه‌های عصبی



دکتر سعید عیسی‌زاده<sup>۱</sup>  
حامد منصوری گرگری<sup>۲</sup>

از صفحه: ۴۹ تا ۷۴  
تاریخ ارایه: ۸۷/۱۱/۱  
تاریخ پذیرش: ۸۷/۱۲/۱۵

### چکیده

امروزه به خاطر افزایش درخواست اعتبارات از بانک‌ها، مطالبات معوق بانک‌ها نیز بیشتر شده است. بنابراین، بانک‌ها برای کاهش مطالبات معوق و بالا بردن کارایی سیستم پولی خود، مجبور شده‌اند که از روش‌های گوناگونی همچون روش سنتی قضاوت شخصی و تحلیل ممیزی برای ارزیابی ریسک اعتباری مشتریان بهره ببرند. با این وجود، در قالب پرداخت‌های کنونی اکثر شرکت‌ها و مشتریان اعتباری اذعان بر ناکافی بودن تسهیلات دریافتی دارند. بنابراین رایحه مدلی که بتواند ریسک و ظرفیت اعتباری مشتریان را به نحو مناسبی تعیین کند، بانک‌ها را قادر خواهد ساخت از تسهیلات جمع‌آوری شده استفاده بهینه‌ای داشته باشند. بدین منظور، در این مقاله با استفاده از مدل شبکه‌های عصبی و اطلاعات ترازنامه‌ای مشتریان بانک تجارت، مدلی برای محاسبه ریسک و ظرفیت اعتباری مشتریان ارایه شده است.

**واژگان کلیدی:** ریسک اعتباری، ظرفیت اعتباری، شبکه‌های عصبی، بانک تجارت.

## مقدمه

محاسبه ریسک و ظرفیت اعتباری بخصوص برای بانکها و موسسات مالی که اقدام به اعطای اعتبار و تسهیلات مختلف به افراد حقیقی و حقوقی می‌کنند، بسیار ضروری است. بنابراین بانکها و موسسات مالی می‌توانند با اندازه‌گیری ریسک و ظرفیت اعتباری و رتبه‌بندی متقاضیان اعتباری، ضمن اینکه بازگشت منابع خود را تضمین می‌کنند، پورتفوی اعتباری خود را با کمترین ریسک و میزان تسهیلات اختصاص داده شده به یک فرد، را به نحو بهینه‌ای تنظیم نمایند. بدین منظور بانکها می‌توانند برای رسیدن به هدف کاهش ریسک اعتباری و تخصیص بهینه اعتبارات، اولاً با اصلاح ساختار اداری و سیستم مدیریت منابع انسانی از طریق آموزش، نسبت به کنترل متغیرهای پژوهش اقدام نموده و با مدیریت این متغیرها سطح بهره‌وری سیستم بانکداری را افزایش دهند. ثانیاً، سیستم بانکداری برای رسیدن به سیستمی کارآمد، باید از یک سیستم پشتیبانی مناسبی بهره‌گیرد. در دهه‌های گذشته، بانکها برای انجام این کار از روش‌های گوناگونی برای ارزیابی و شناسایی مشتریان بهره گرفته‌اند. به عنوان مثال بی‌ور<sup>۱</sup> در سال ۱۹۶۷ با استفاده از تعدادی شاخص سعی نمود موفقیت و شکست شرکت‌ها را برآورد نماید. پس از آن مطالعه، آلتنمن<sup>۲</sup> در سال ۱۹۶۸ تلاش بسیاری برای یافتن یک رابطه معنی‌دار بین متغیرهای حسابداری یک شرکت و احتمال عدم توانایی در پرداخت دیون این شرکت در آینده انجام داد و رابطه‌ای معروف به Z-Score را ارائه داد.

این روش مبتنی بر تحلیل تفکیک خطی بین شرکت‌های خوب و بد بود و بر اساس آن فقط شرکت‌های خوب از بد جدا می‌شدند. با اینکه این روش بسیار ابتدایی بود اما تا حدودی وضعیت شرکت‌های بد را می‌توانست پیش‌بینی کند و تا سال ۱۹۸۰ روش غالب اکثر مطالعات بود. پیچیز و مینگو<sup>۳</sup> از روش تحلیل تفکیک خطی چندگانه (MDA) در تعیین یک تابع تفکیک از چندین متغیر مستقل و یک متغیر وابسته استفاده نمودند و دقت رتبه‌بندی اوراق را بهبود بخشیدند. دیکینز<sup>۴</sup> در سال ۱۹۷۲ تحلیل ممیزی را به منظور ارزیابی شکست شرکت‌ها مورد استفاده قرار داد. مجدداً در همین زمینه مطالعات ارزشمندی در سال‌های ۱۹۹۳ و ۱۹۹۵ در زمینه ورشکستگی مالی شرکت‌ها و پیش‌بینی انحطاط مالی شرکت‌ها انجام داد.

1- Beaver

2- Altman

3- Piches &amp; Mingo

4- Deakins

آلتن، آوری، ایسن بیس و سینکی<sup>۱</sup> در سال ۱۹۸۰ از مدل رگرسیون لاجستیک و تحلیل سود برای رتبه‌بندی شرکت‌ها مورد استفاده قرار دادند و نسبت‌های مالی را در مطالعات خود به عنوان متغیرهای تاثیرگذار استفاده نمودند و فرض را بر این قرار دادند که متغیرها دارای اطلاعات کاملی از وضعیت شرکت‌ها می‌باشند.

اخیراً، روش‌های هوش مصنوعی، بخصوص سیستم‌های مبتنی بر پایگاه قواعد و روش‌های یادگیری ماشین مانند شبکه‌های عصبی و الگوریتم ژنتیک برای چنین تحلیل‌هایی به کار می‌روند. روش‌های هوش مصنوعی به طور خودکار از مجموعه داده‌ها کسب دانش نموده و مدل‌های مختلفی را در تشریح وضعیت ارائه می‌دهند. از جمله تحقیقات انجام شده در این زمینه می‌توان به کاربرد موفق شبکه‌های عصبی در پیش‌بینی رتبه‌بندی اوراق قرضه با دقت  $83/3\%$  در سال ۱۹۸۸ توسط شخار<sup>۲</sup> و داتا<sup>۳</sup> اشاره نمود. همچنین سینگلتون و سورکان<sup>۳</sup> در سال ۱۹۹۰ با استفاده از یک شبکه عصبی پس انتشار موفق به رتبه‌بندی اوراق قرضه با دقت  $88\%$  گردیدند. همچنین این مدل را با تحلیل تفکیک چندگانه مقایسه نموده و نشان دادند که شبکه عصبی دارای دقت بیشتری در پیش‌بینی می‌باشد.

همانطور که از مطالب بالا مشهود است اکثر مطالعات انجام شده بر روی ریسک اعتباری متمرکز شده‌اند. اما عامل مهمی همچون ظرفیت اعتباری مشتریان که می‌تواند در ارائه تسهیلات به بانک‌ها و موسسات کمک شایانی نماید، مورد توجه قرار نگرفته است.

بنابراین، با توجه به مطالب بالا، سوالی که به ذهن خطور می‌کند، این است که آیا می‌توان مدلی برای ارزیابی ریسک و ظرفیت اعتباری مشتریان بانک با استفاده از مدل‌های توسعه داده شده‌ای همچون شبکه‌های عصبی طراحی و ریسک اعتباری بانک‌های تجاری را در استفاده از تسهیلات بانکی کاهش داد؟

برای پاسخ به این سوال، در این مقاله پس از بررسی کامل مدل شبکه‌های عصبی، مواردی همچون کاربردهای تحقیق، قلمرو مکانی و زمانی تحقیق، جنبه‌های ابتکار و نوآوری تحقیق، نمونه آماری، متغیرهای پژوهش، مدل کاربردی و نتایج آن، مورد توجه قرار گرفته است و در نهایت خلاصه و نتیجه‌گیری و پیشنهادات مقاله ارائه گردیده است. در محاسبات و تجزیه و تحلیل‌های آماری از نرم‌افزارهای Eviews 5 و Neural Work استفاده شده است.

1- Altman, Avery, Eisenbeis & Sinky

2- Shekhar & Dutta

3- Singleton & Surkun

## شبکه‌های عصبی

### تاریخچه شبکه‌های عصبی

بعضی از پیش‌زمینه‌های شبکه‌های عصبی را می‌توان به اوایل قرن بیستم و اواخر قرن نوزدهم برگرداند. در این دوره کارهای اساسی در فیزیک، روانشناسی و نرولوژی توسط علمایی چون هرمان فون هلمهلتز<sup>۱</sup>، ارنست ماخ<sup>۲</sup>، و ایوان پاولف<sup>۳</sup> صورت پذیرفت. این کارهای اولیه عموماً بر تئوری‌های بینایی و شرطی تاکید داشته‌اند و اصلاً به مدل‌های مشخص ریاضی عملکرد نرون‌ها اشاره‌ای نداشته‌اند.

دیدگاه جدید در دهه ۴۰ قرن بیستم آغاز شد، زمانی که وارن مک کلوث<sup>۴</sup> و والتر پیترز<sup>۵</sup> نشان دادند که شبکه‌های عصبی می‌توانند هر تابع حسابی منطقی<sup>۶</sup> را محاسبه نمایند. کار این افراد را می‌توان نقطه شروع حوزه علمی شبکه‌های عصبی مصنوعی نامید و این موضوع با دونالد هب<sup>۷</sup> ادامه یافت؛ شخصی که عمل شرط‌گذاری کلاسیک را که توسط ایوان پتروویچ پاولف<sup>۸</sup> مطرح شده بود به عنوان خواص نرون‌ها معرفی نمود و سپس مکانیسمی را جهت یادگیری نرون‌های بیولوژیکی ارائه داد.

نخستین کاربرد عملی شبکه‌های عصبی در اواخر دهه ۵۰ قرن بیستم مطرح شد، زمانی که فرانک روزنبلات<sup>۹</sup> در سال ۱۹۵۸ شبکه پرسپترون را معرفی نمود. روزنبلات و همکارانش شبکه‌ای ساختند که قادر بود الگو را از هم شناسایی نماید. در همین زمان بود که برنارد ویدرو<sup>۱۰</sup> در سال ۱۹۶۰ شبکه عصبی تطبیقی خطی آدلاین<sup>۱۱</sup> را با قانون یادگیری جدید مطرح نمود که از لحاظ ساختار، شبیه شبکه پرسپترون بود.

پیشرفت شبکه‌های عصبی تا دهه ۷۰ قرن بیستم ادامه یافت. در ۱۹۷۲ تئوکوهنن<sup>۱۲</sup> و جیمز اندرسون<sup>۱۳</sup> به طور مستقل و بدون اطلاع از هم، شبکه‌های عصبی جدیدی را معرفی نمودند که

- 
- 1- Hermann von Helmholtz
  - 2- Ernst Mach
  - 3- Ivan Pavlov
  - 4- Warren McCulloch
  - 5- Walter Pitts
  - 6- Arithmetic & Logical Function
  - 7- Donald Hebb
  - 8- Ivan Petrovitch Pavlov
  - 9- Frank Rosenblatt
  - 10- Bernard Windrow
  - 11- Adaptive Linear Element(ADALINE)
  - 12- Teo Kohonen
  - 13- James Anderson

قادر بودند به عنوان عناصر ذخیره‌ساز عمل نمایند. استفان گروسبرگ<sup>۱</sup> در این دهه روی شبکه‌های خودسازمانده فعالیت می‌کرد. فعالیت در زمینه شبکه‌های عصبی در دهه ۶۰ قرن بیستم در قیاس با دهه ۸۰- به علت عدم بروز ایده‌های جدید و نبود کامپیوترهای سریع جهت پیاده‌سازی- کم‌رنگ می‌نمود. لکن در خلال دهه ۸۰، رشد تکنولوژی میکروپروسورها روند صعودی داشت و تحقیقات روی شبکه‌های عصبی فزونی یافت و ایده‌های جدیدی مطرح شدند. در این زایش دوباره شبکه‌های عصبی دو نگرش جدید قابل تامل می‌باشد. این ایده‌ها شامل شبکه‌های برگشتی<sup>۲</sup> و الگوریتم پس انتشار خطا<sup>۳</sup> بودند که توسط دانشمندانی همچون جان هاپفیلد<sup>۴</sup> دیوید راملهارت<sup>۵</sup> و جیمز مک‌کلند<sup>۶</sup> مطرح گردید. با بروز این دو ایده، شبکه‌های عصبی متحول شدند. در ده سال اخیر هزاران مقاله نوشته شده و شبکه‌های عصبی کاربردهای زیادی در رشته‌های مختلف علوم پیدا کرده است و در این راستا به کارگیری شبکه‌های عصبی با توجه به پیشرفت‌های قابل توجه در پردازش سریع‌تر اطلاعات به وسیله کامپیوترها و نرم‌افزارهای کاربردی، انگیزه پژوهش و به کارگیری مدل‌های غیرخطی را در میان اقتصاددانان به طور چشم‌گیری افزایش داده است. اصلی‌ترین و مهم‌ترین کاربرد مدل‌های شبکه‌های عصبی مصنوعی در اقتصاد، پیش‌بینی متغیرهای اقتصادی است. این شبکه‌ها برای مدل‌سازی و پیش‌بینی، از یک مجموعه رگرورها (متغیرهای ورودی) استفاده می‌کنند. منظور از مدل‌سازی، مشخص کردن مدل<sup>۷</sup>، تخمین پارامترها و در نهایت، ارزیابی مدل برآورد شده است.

### چرا شبکه‌های عصبی مصنوعی؟، تشابهات و انتظارات

در سیستم عصبی، نرون‌ها (سلول‌های عصبی) به عنوان اصلی‌ترین عنصر پردازش، شناخته شده‌اند. به طور کلی بدن انسان در حدود ۱۰۰ تریلیون نرون وجود دارد که تمام آن‌ها از سه قسمت اصلی تشکیل شده‌اند: بدنه سلول، دندریت‌ها و آکسون شکل شماره (۱). همان طور که در شکل مشخص است هر نرون دارای تعدادی دندریت و یک آکسون است. دندریت‌ها به عنوان مناطق دریافت‌کننده سیگنال‌های الکتریکی هستند و سیگنال‌های الکتریکی را از آکسون‌های دیگر به

1- Stefan Grossberg

2- Feedback (Recurrent)

3- Error Back Propagation


4- John Hopfield

5- David Rummelhart


6- James Mcland

7- model specification

بدنه سلول می‌برند. بدنه سلول انرژی لازم را برای فعالیت نرون فراهم کرده و بر روی سیگنال‌های ورودی عمل می‌کند (که با یک عمل جمع جبری ساده و مقایسه با یک سطح آستانه مدل می‌گردد). آکسون نیز سیگنال‌های الکتروشیمیایی را از بدنه سلول به دندریت سایر نرون‌ها منتقل می‌کند. محل تلاقی یک آکسون از یک نرون به دندریت‌های سایر نرون‌ها را سیناپس می‌نامند. سیناپس‌ها واحدهای کوچکی هستند که ارتباط بین نرون‌ها را برقرار می‌سازد. زمانی که سیگنال‌های عصبی از آکسون سایر نرون‌ها به یک نرون می‌رسد، آن را تحریک می‌کند. نرون از هر یک از اتصالات ورودی خود یک ولتاژ کم را توسط سیگنال‌های عصبی، دریافت می‌کند و آن‌ها را با هم جمع می‌کند. اگر این مقدار به مقدار آستانه برسد، نرون آتش می‌شود و به آکسون خود یک ولتاژ خروجی ارسال می‌نماید و آکسون نیز با توجه به شدت آن، ممکن است یک سیگنال را توسط سیناپس، به دندریت نرون‌های دیگر بفرستد یا اینکه به دلیل ضعیف بودن آن، هیچ‌گونه سیگنالی را عبور ندهد. و به همین ترتیب تمامی فعالیت‌های مغزی انسان انجام می‌شود.



شکل شماره ۱): ساختار یک سلول عصبی انسان



شکل شماره ۲): ساختار شبکه عصبی مصنوعی

با این دید اجمالی از نحوه عملکرد نرون، باید سیستمی طراحی شود که دارای تعدادی ورودی باشد که با توجه به اهمیت هر یک، آن‌ها را با یکدیگر جمع ساده جبری نماید و توسط یک تابع موسوم به تابع تبدیل، آن‌ها را به نرون‌های دیگر ارسال نماید. شکل شماره (۲) الگویی از یک واحد پردازش با توجه به نحوه عملکرد یک نرون ارائه می‌دهد. همان‌گونه که مشاهده می‌شود، آکسون را می‌توان به خروجی، وزن را به ولتاژ و ورودی‌ها را به دندریت‌ها تشبیه نمود.

بنابراین اجزای یک شبکه عصبی عبارتند از:

- **ورودی‌ها ( $p_i$ )**. ورودی‌ها می‌توانند خروجی سایر لایه‌ها بوده و یا آنکه به حالت خام در اولین لایه و به صورت‌های زیر باشند:
  - ۱- داده‌های عددی در مبنای ۲، ۸، ۱۰، ۱۶ و ....
  - ۲- متون ادبی، فنی و ...
  - ۳- تصویر و یا شکل
- **وزن‌ها ( $W_i$ )**. میزان تاثیر ورودی  $p_i$  بر خروجی  $a$ ، توسط وزن اندازه‌گیری می‌شود.
- **تابع جمع**. در شبکه‌های تک نرونی، تابع جمع در واقع خروجی مساله را تا حدودی مشخص می‌کند و در شبکه‌های چند نرونی نیز میزان سطح فعالیت نرون  $j$  در لایه درونی را مشخص می‌سازد. این تابع در ادبیات شبکه‌های عصبی، به ورودی خالص ( $NetInput$ ) معروف است و برابر است با:

$$Net = (w_1 p_1 + w_2 p_2 + w_3 p_3) + b = \sum_{i=1}^3 w_i p_i + b = WP + b \quad (1)$$

- **تابع تبدیل یا تابع فعال‌سازی**<sup>۱</sup>  
 بدیهی است که تابع فعال‌سازی پاسخ مورد انتظار شبکه نیست. تابع فعال‌سازی، عضوی ضروری در شبکه‌های عصبی محسوب می‌گردد. انواع و اقسام متفاوتی از توابع تبدیل وجود دارد که بنا به ماهیت مساله کاربرد دارند. رایج‌ترین توابع فعال‌سازی مورد استفاده در ادبیات شبکه‌های عصبی توابع توزیع تجمعی لجستیک<sup>۲</sup>، تانژانت هیپربولیک<sup>۳</sup>، تابع گوسین<sup>۴</sup> و تابع آستانه‌ای<sup>۵</sup> هستند که توسط طراح مساله انتخاب می‌گردند و بر اساس الگوریتم یادگیری، پارامترهای مساله (وزن‌ها) تنظیم می‌گردند.
- **خروجی**<sup>۶</sup>. منظور از خروجی، پاسخ شبکه است.

## انواع شبکه‌های عصبی مصنوعی از نظر برگشت‌پذیری

### شبکه‌های پیش‌خور


شبکه‌های پیش‌خور، شبکه‌هایی هستند که مسیر پاسخ در آن‌ها، همواره رو به جلو پردازش

---

1- Activation Function  
 2- Logistic Cumulative Distribution Function  
 3- Hyperbolic Tangent  
 4- Gaussian  
 5- Threshold  
 6- Output



می‌شود و به نرون‌های لایه‌های قبل باز نمی‌گردد. در این نوع شبکه‌ها به سیگنال‌ها اجازه می‌دهند تنها از مسیر یک‌طرفه عبور کنند، یعنی از ورودی تا خروجی. بنابراین باز خوردی (فیدبکی) وجود ندارد، به این معنی که خروجی هر لایه تاثیری بر همان لایه ندارد. در بدن انسان نیز، پیام‌های عصبی به صورت یک‌طرفه حرکت می‌کنند: از دزیت به بدنه سلول و سپس به آکسون. شکل شماره (۳) نمونه‌ای از یک شبکه پیش‌خور را نشان می‌دهد.



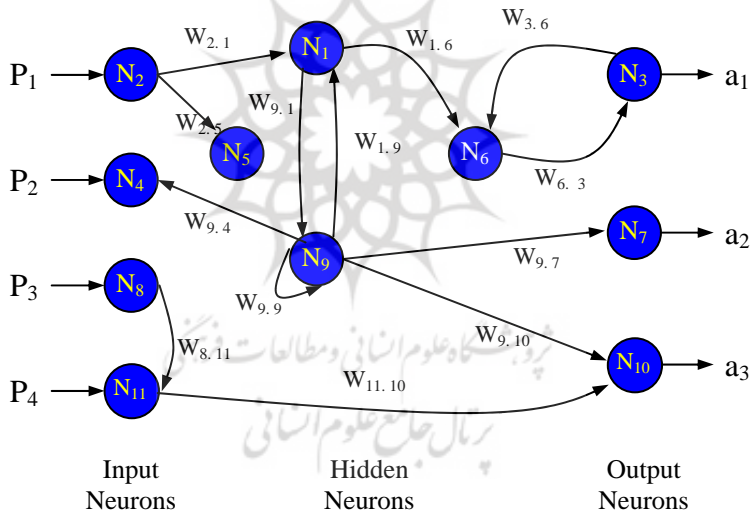
شکل شماره ۳): نمونه‌ای از یک شبکه پیش‌خور

با در نظر گرفتن توابع فعال‌سازی مختلف می‌توان به مدل‌های اقتصادسنجی رایجی همچون مدل‌های چند متغیره، لاجیت و پروبیت ... دست یافت. در کاربردهای واقعی، ساختمان شبکه معمولاً بسیار پیچیده است. شبکه‌های عصبی پیش‌خور با انواع توابع فعال‌سازی، تعداد لایه‌ها و تعداد نرون‌های هر لایه، یک مجموعه متنوعی را تشکیل می‌دهند که بسته به نوع مسایل موجود انتخاب می‌شوند. البته لازم به ذکر است که شبکه‌های عصبی با لایه‌های پنهان دارای توانایی‌های بیشتری نسبت به شبکه‌های عصبی دو لایه هستند. (شیری و قدیمی، ۱۳۸۱)

### شبکه‌های پس‌خور<sup>۱</sup> (برگشتی)

تفاوت شبکه‌های برگشتی با شبکه‌های پیش‌خور در آن است که در شبکه‌های برگشتی حداقل یک سیگنال برگشتی از یک نرون به همان نرون یا نرون‌های همان لایه یا نرون‌های لایه‌های قبل

وجود دارد و اگر نرونی دارای فیدبک باشد بدین مفهوم است که خروجی نرون در لحظه حال نه تنها به ورودی در آن لحظه بلکه به مقدار خروجی خود نرون، در لحظه گذشته نیز بستگی دارد. شبکه‌های برگشتی بهتر می‌توانند رفتار مربوط به ویژگی‌های زمانی و پویایی سیستم‌ها را نشان دهند. در این نوع شبکه‌ها که با توجه به ماهیت پویای مساله طراحی می‌شوند بعد از مرحله یادگیری شبکه نیز، پارامترها تغییر کرده و تصحیح می‌شوند. این شبکه‌ها پویا هستند، و وضعیت آن‌ها پیوسته در حال تغییر است تا اینکه آن‌ها به یک نقطه تعادل برسند. آن‌ها در این وضعیت تعادل باقی می‌مانند تا زمانی که ورودی تغییر کند و نیاز باشد تا تعادل تازه‌ای پیدا شود. از ساده‌ترین این شبکه‌ها، می‌توان به شبکه‌های پفیلد اشاره نمود. شکل شماره (۴) نمونه‌ای از یک شبکه پسخور را نشان می‌دهد.



شکل شماره ۴): شبکه پسخور (برگشتی)

### فرایند یادگیری در شبکه‌های عصبی

در فضایی نظیر هوش مصنوعی، یادگیری بر مبنای یک معنای عام‌تر، قابل مقایسه با مراحل خودسازی که به وسیله انسان‌ها مورد استفاده قرار می‌گیرند می‌باشد. یک روش یادگیری می‌تواند ساختار درونیش را برای بدست آوردن جواب بهتر، بر مبنای کارایی تعیین شده پیشین، سازگار

کند. میزان کارایی می‌تواند خطا یا اختلاف بین خروجی واقعی و خروجی مطلوب سیستم باشد. مفهوم یادگیری در شبکه‌های عصبی با بسیاری از روش‌های آموزشی شبکه‌های عصبی مبتنی بر رفع خطا مرتبط است و این بدین معنی است که وزن‌های موجود در شبکه به گونه‌ای تغییر نماید که فاصله بین خروجی‌های شبکه با مقدار واقعی حداقل شود. باید به خاطر داشت که این عمل در مورد داده‌های آزمایشی مصداق دارد، عمل یا تغییر و تنظیم وزن‌های متصله بین یک شبکه برای حصول به یک ساختار مشخص و یا ایجاد یک نگاشت مشخص و یا ایجاد یک نگاشت مطلوب، یادگیری نامیده می‌شود. (Robert, 1997)

در آموزش شبکه عصبی، الگوی مشخص شده‌ای به همراه پاسخ مورد نظر به شبکه داده می‌شود و شبکه با تغییر وزن‌های شبکه سعی می‌کند خطای بین مقادیر واقعی و خروجی شبکه را حداقل کند. در شبکه‌های عصبی، هر چه مشاهدات کامل‌تر باشد آنچه انتزاع شده است، صحیح‌تر خواهد بود. البته، این احتمال وجود دارد که برخی مشاهدات گمراه کننده بوده و با روش کلی مشاهدات هماهنگ نباشد. بنابراین، آنچه که به عنوان نمونه‌های آموزشی در اختیار شبکه عصبی قرار می‌گیرد، تا حد امکان باید پالایش شده و همسان باشند.

یک شبکه عصبی پس از مدتی کاربرد، نیاز به آموزش‌های مجدد برای تعمیق و گسترش دانایی خود دارد. آموزش چنانچه شامل نمونه‌های جدید و یا نمونه‌هایی که قبلاً خوب آموزش داده نشده است باشد، بسیار موثر خواهد بود. روش‌های یادگیری شبکه‌های عصبی متعدد بوده و معمولاً در مورد هر نوع شبکه، روش یادگیری متناسب با آن انتخاب می‌شود.

شبکه‌های عصبی چند لایه پرسپترون<sup>۱</sup> با الگوریتم پس انتشار خطا<sup>۲</sup>، یکی از متداول‌ترین شبکه‌های کاربردی است، در مباحث نظری اثبات شده که این نوع شبکه با انتخاب ساختار مناسب داخلی، قادر است هرگونه سیستم غیرخطی را مدل کرده و شبیه‌سازی کند.

### الگوریتم پس انتشار خطا (BP)

به منظور برآورد مقادیر مطلوب بردار وزن‌ها از روش‌های متعددی استفاده می‌شود که مهمترین و پرکاربردترین آن‌ها که اغلب در شبکه‌های پرسپترون چند لایه مورد استفاده قرار می‌گیرد، الگوریتم پس انتشار خطا<sup>۳</sup> می‌باشد. (Hayking, 1994: 144-152)

1- Multi Layer Perceptron (MLP)  
2- Back Propagation Algorithm  
3- Back Propagation Algorithm

در این روش همچنان که از عنوان آن بر می آید، برای آموزش شبکه چند لایه پیش خور استفاده می کنند. به عبارتی توپولوژی شبکه های پرسپترون چند لایه، با قانون یادگیری پس انتشار خطا تکمیل می شود. قانون پس انتشار خطا از دو مسیر اصلی تشکیل می شود. مسیر اول به مسیر رفت<sup>۱</sup> موسوم می باشد که در این مسیر بردار ورودی به شبکه MLP اعمال می شود و تاثیراتش از طریق لایه های میانی به لایه های خروجی انتشار می یابد. بردار خروجی تشکیل یافته در لایه خروجی، پاسخ واقعی شبکه MLP را تشکیل می دهد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می شوند.

مسیر دوم به مسیر برگشت<sup>۲</sup> موسوم است. در این مسیر، برعکس مسیر رفت، پارامترهای شبکه MLP تغییر و تنظیم می گردند. این تنظیم مطابق با قانون اصلاح خطا انجام می گیرد. سیگنال خطا، در لایه خروجی شبکه تشکیل می گردد. و مقدار خطا، پس از محاسبه، در مسیر برگشت از لایه خروجی و از طریق لایه های شبکه، در کل شبکه توزیع می گردد. پارامترهای شبکه طوری تنظیم می شوند که پاسخ واقعی شبکه هر چند بیشتر، به سمت پاسخ مطلوب نزدیکتر شود.

الگوریتم BP برای شبکه های MLP تعمیمی از الگوریتم LMS<sup>۳</sup> می باشد. این شاخص میانگین مربعات خطا می باشد که در چارچوب یادگیری، با زوج داده های یادگیری زیر قرار می گیرد:<sup>۴</sup>

$$\left\{ (\underline{p}^1, \underline{t}^1), (\underline{p}^2, \underline{t}^2), \dots, (\underline{p}^Q, \underline{t}^Q) \right\}$$

جایی که  $\underline{P}^i$  بردار ورودی شبکه و  $\underline{t}^i$  خروجی مطلوب شبکه برای ورودی  $\underline{P}^i$  است. پس از اعمال ورودی  $\underline{P}(k)$  (K امین الگو) به شبکه - که یکی از  $\underline{P}^i$  ها می باشد - سیگنال خطا در خروجی نرون  $j$ ام از لایه خروجی (لایه L<sup>۵</sup>) در لحظه K یا تکرار K ام، از روی رابطه زیر بدست می آید:

$$\underline{e}_j(k) = \underline{t}_j(k) - \underline{a}_j(k)$$

جایی که  $\underline{t}_j(k)$  عنصر  $j$ ام از بردار جواب مطلوب متناظر با بردار ورودی  $\underline{P}(k)$  می باشد. مقدار لحظه ای مربع خطا برای نرون  $j$ ام از لایه خروجی، به شکل  $e_j^2(k)$  تعریف می شود.

- 
- 1- Forward Path
  - 2- Backward Path
  - 3- Least Mean Square

۴- علامت ( ) زیر حروف نشانگر ماتریسی بودن متغیرها است.

۵- L تعداد لایه های شبکه را مشخص می کند.

متعاقباً مقدار لحظه‌ای جمع مربعات خطا، با جمع  $e_j^2(k)$  برای تمامی نرون‌ها در لایه خروجی به دست می‌آید. توجه داریم که تنها نرون‌های لایه خروجی به عنوان نرون‌های قابل مشاهده در نظر گرفته می‌شوند، بنابراین رفتار شبکه با شاخص اجرایی زیر بیان می‌گردد:

$$\hat{F}(k) = \sum_{j=1}^{S_L} e_j^2(k)$$

جایی که  $S_L$  تعداد نرون‌ها در لایه  $L$  می‌باشد. توجه داریم که در تئوری، شاخص اجرایی برای تنظیم پارامترهای شبکه با رابطه زیر بیان می‌شود:

$$F(k) = E(\hat{F}(k))$$

و در عمل همانند الگوریتم LMS از شاخص اجرایی زیر:

$$\hat{F}(k) = \sum_{j=1}^{S_L} e_j^2(k) = \underline{e}^T(k) \cdot \underline{e}(k)$$

برای تنظیم پارامترهای شبکه استفاده می‌شود. به عبارت دیگر پارامترهای شبکه، ماتریس‌های وزن و بردارهای بایاس طوری تنظیم می‌شوند تا مجموع مربعات خطای لحظه‌ای  $\hat{F}(k)$ ، می‌نیم گردد. در رابطه فوق بردار خطای  $\underline{e}$  برابر است با:

$$\underline{e}(k) = \underline{t}(k) - \underline{a}(k)$$

و این مساله می‌نیم‌سازی، الگوریتم تقریبی بیشترین کاهش را ایجاد می‌کند.

به طور خلاصه معادلات مسیر رفت، برگشت و تنظیم پارامترهای شبکه به صورت زیر بیان می‌گردد. [۳]

## مسیر رفت

$$\underline{a} = \underline{p}(k)$$

$$\underline{a}^{l+1}(k) = \underline{F}^{l+1}(\underline{W}^{l+1}(k)\underline{a}^l + \underline{b}^{l+1}(k)) \quad , \quad l = 0, 1, 2, \dots, L-1$$

$$\underline{a}(k) = \underline{a}^L(k)$$

در این مسیر همان‌گونه که می‌بینیم پارامترهای شبکه در خلال اجرای محاسبات رفت تغییر

نمی‌کنند و توابع محرک، روی تک تک نرون‌ها عمل می‌کند، یعنی:

$$\underline{F}^{l+1}(\underline{n}(k)) = \left[ f^{l+1}(n_1(k)) \dots f^{l+1}(n_{S_{l+1}}(k)) \right]^T$$

مسیر برگشت: در این مسیر بردارهای حساسیت ( $\underline{\delta}$ ) از لایه آخر به لایه اول برگشت داده می‌شوند. معادلات زیر دینامیک مسیر برگشت را بیان می‌کنند:

$$\underline{\delta}^L(k) = -2\dot{F}^L(n)\underline{e}(k)$$

$$\underline{\delta}^l(k) = \dot{F}^l(\underline{n}^l) \left( W^{l+1} \right)^T \underline{\delta}^{l+1}, \quad l = L-1, L-2, \dots, 1$$

$$\underline{e}(k) = \underline{t}(k) - \underline{a}(k)$$

$$\dot{F}^l(\underline{n}^l(k)) = \frac{\partial \underline{a}^l(k)}{\partial \underline{n}^l(k)}$$

به عبارت دیگر در مسیر برگشت، شروع کار از لایه آخر، لایه خروجی است، جایی که بردار خطا در اختیار می‌باشد. سپس بردار خطا از سمت راست به چپ از لایه آخر به لایه اول توزیع می‌شود و گرادینان محلی، نرون به نرون با الگوریتم بازگشتی محاسبه می‌شود. در این مسیر هم پارامترهای شبکه تغییر نخواهند کرد.

**تنظیم پارامترها:** نهایتاً ماتریس‌های وزن و بردارهای بایاس شبکه با روابط زیر تنظیم می‌گردند:

$$W^l(k+1) = W^l(k) - \alpha \underline{\delta}^l(k) \left( \underline{a}^{l-1}(k) \right)^T$$

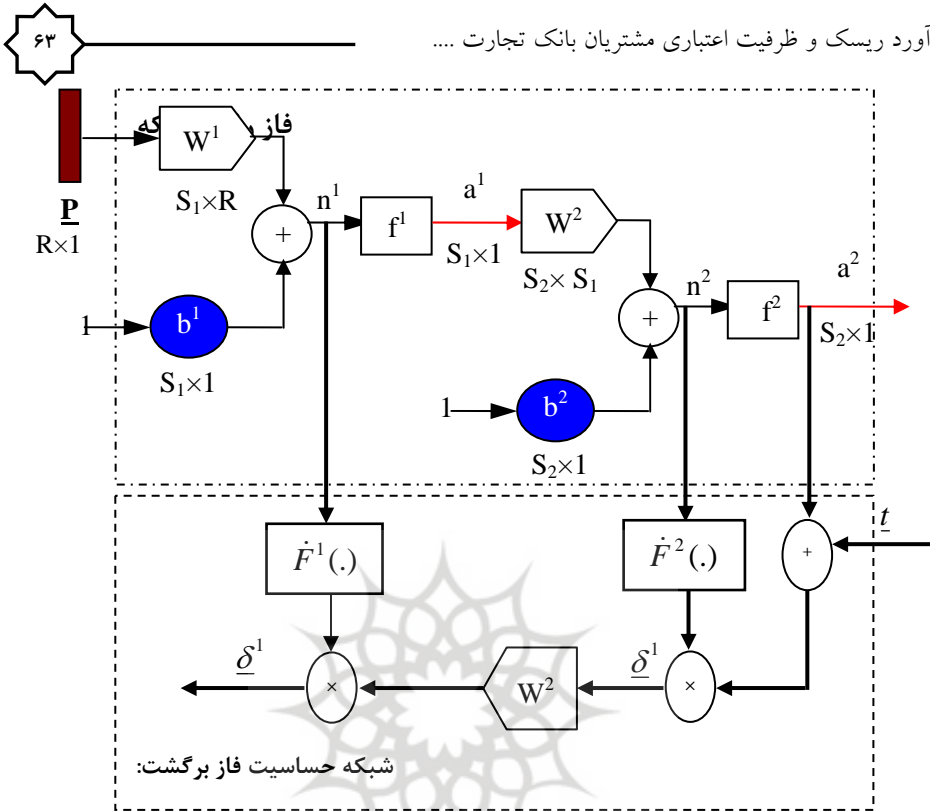
$$\underline{b}^l(k+1) = \underline{b}^l(k) - \alpha \underline{\delta}^l(k), \quad l = 1, 2, \dots, L$$

در اینجا  $\alpha$  نرخ یادگیری است که برای همگرایی الگوریتم با توجه به شرط زیر انتخاب می‌گردد:

$$0 < \alpha < \frac{1}{\text{Trace}[R]}, \quad R = E(\underline{P}\underline{P}^T)$$

$\text{Trace}[R]$ : جمع عناصر قطر اصلی ماتریس  $R$  یا جمع مقادیر ویژه ماتریس  $R$

توجه داریم که پس از اعمال هر زوج ورودی - خروجی به عنوان الگوی یادگیری، بردارهای ورودی در خلال سه مرحله فوق تغییر نمی‌کنند. به همین دلیل شماره مرحله تکرار  $\mathbf{K}$  عملاً با اعمال الگو به شبکه معادل است. شکل شماره (۵) رفتار کل شبکه را نمایش می‌دهد.



شکل شماره ۵): با یک لایه مخفی همراه با برگشت حساسیت‌ها MLP

توقف: جهت توقف تکرار الگوریتم BP از دو شاخص زیر به طور همزمان می‌توان استفاده نمود.  
 الف- میانگین مربعات خطا در هر سیکل (جمع مربعات خطا برای تمامی الگوهای یادگیری) کمتر از مقدار از پیش تعیین شده‌ای باشد. باید توجه داشت که هر سیکل برابر با تعداد تکرار، به اندازه تعداد نمونه‌های یادگیری می‌باشد. مثلاً اگر ۱۰۰ تا داده‌های نمونه یادگیری موجود است، سیکل برابر با ۱۰۰ مرحله تکرار می‌گردد.

ب- نرم گرادیان خطا خیلی کوچک باشد: نرم گرادیان خطا از یک مقدار از پیش تعیین شده‌ای کوچکتر گردد. (منهاج، ۱۳۷۹)

### کاربردهای تحقیق

ریسک اعتباری به عنوان یکی از مهمترین شاخص در انتخاب مشتری و اعطای تسهیلات و سرمایه‌گذاری مورد توجه بانک‌ها و موسسات مالی است. بنابراین بانک‌ها و موسسات مالی

می‌توانند یکی از استفاده کنندگان این پژوهش باشند.

سازمان‌ها و شرکت‌های سرمایه‌گذاری سهام می‌توانند برای تجزیه و تحلیل صورت‌های مالی شرکت‌ها از مدل به کار برده شده، استفاده نمایند. دانشجویان، محققان، شرکت‌های بیمه و سرمایه‌گذاران سهام از جمله استفاده کنندگان این تحقیق نیز محسوب می‌گردند که می‌توانند برای تحقیق و پژوهش، صدور بیمه‌نامه و ارزیابی سهام شرکت‌های سهامی از نتایج نهایی آن بهره ببرند.

### قلمرو مکانی و زمانی تحقیق

این تحقیق بر روی مشتریان اعتباری بانک طراحی شده است و نظر به اینکه متغیرهایی همچون ریسک و ظرفیت اعتباری برای موسسات مالی و اعتباری مثل بانک‌ها از اهمیت بالایی برخوردار است سازمان‌ها، موسسات مالی و اعتباری می‌توانند از یافته‌های این تحقیق استفاده کنند. قلمرو تحقیق شامل مشتریان بانک تجارت به عنوان نمونه آماری و اطلاعات، مدارک و مستندات موجود در ترازنامه اعتباری مشتریان است. از نظر زمانی، داده‌ها و اطلاعات مورد استفاده مربوط به مشتریانی است که از سال ۱۳۸۰ تا ۱۳۸۵ اقدام به دریافت وام و اعتبار نموده‌اند.

### جنبه‌های ابتکار و نوآوری تحقیق

یکی از جنبه‌های ابتکار این تحقیق ارایه مدل ریاضی برای ارزیابی ریسک و ظرفیت اعتباری مشتریان بانک تجارت است. همچنین می‌توان ارزیابی هم‌زمان ریسک و ظرفیت اعتباری مشتریان بانک تجارت با استفاده از شبکه‌های عصبی را نیز به عنوان جنبه دیگر ابتکار و نوآوری این تحقیق در نظر گرفت.

### نمونه آماری

با توجه به استفاده از شبکه‌های عصبی و مدل‌های آماری باید تعدادی از مشتریان گذشته بانک تجارت که دارای خصوصیات مورد نظر تحقیق بودند به عنوان نمونه آماری انتخاب می‌شدند بنابراین ۵۰۰ نفر از مشتریان اعتباری بانک تجارت به عنوان نمونه انتخاب گردیدند و سپس از بین این تعداد مشتریان موجود بانکی حدود ۱۲۲ نفر که دارای اطلاعات کامل بودند برای تجزیه و تحلیل لحاظ گردید، از بین این مشتریان ۹۰ نفر برای برآورد و تخمین مدل‌های به کار برده شده و حدود ۳۲ نفر به عنوان داده‌های آزمایش مورد توجه قرار گرفت.



## متغیرهای پژوهش

متغیرهای تحقیق به دو قسمت متغیرهای وابسته و مستقل تقسیم می‌شوند.

• متغیرهای وابسته عبارتند از:

۱- ریسک اعتباری مشتریان (احتمال بازپرداخت تسهیلات دریافتی از سوی مشتریان

به بانک‌ها، موسسات مالی و ....)

۲- ظرفیت اعتباری مشتریان (حجم اعتباری که هر مشتری می‌تواند دریافت نماید).

در مطالعات انجام شده برای برآورد ریسک و ظرفیت اعتباری، محققان از تکنیک آماری تحلیل عاملی<sup>۱</sup> برای شناسایی متغیرهای تاثیرگذار (مستقل) استفاده کرده‌اند. با توجه به اینکه هدف از این تحقیق محاسبه ریسک و ظرفیت اعتباری مشتریان بانک تجارت است، متغیرهای مورد استفاده محققان<sup>[۱]</sup> به عنوان متغیرهای اصلی پژوهش جهت آزمون انتخاب گردید. البته متغیرهای دیگری که از اطلاعات ترازنامه‌ای مشتریان بانک تجارت بدست می‌آید نیز مورد بررسی قرار گرفت. در نهایت با تایید متغیرهای مورد استفاده دیگر پژوهش‌گران متغیرهای زیر به عنوان متغیرهای تاثیرگذار انتخاب گردید:

۱- نوع فعالیت شرکت (خدماتی  $(X_{IKH})$ ، تولیدی  $(X_{IT})$ ، بازرگانی  $(X_{IB})$ ، کشاورزی  $(X_{IK})$ )

۲- سابقه فعالیت شرکت  $(X_2)$

۳- سابقه مدیر یا مدیر عامل شرکت  $(X_3)$

۴- جمع گردش بدهکار نزد بانک  $(X_4)$

۵- جمع گردش بستانکار نزد بانک  $(X_5)$

۶- جمع دارایی‌های جاری  $(X_6)$

۷- جمع بدهی‌های جاری  $(X_7)$


۸- جمع دارایی‌های ثابت  $(X_8)$

۹- نرخ بازده سرمایه  $(X_9)$

۱۰- سرمایه ثبت شده  $(X_{10})$

## مدل کاربردی و نتایج آن

شبکه‌های عصبی به عنوان یکی از پرکاربردترین مدل‌ها در برآورد و پیش‌بینی دارای انعطاف و قابلیت‌های زیادی است. همانطور که می‌دانیم شبکه‌های عصبی را می‌توان برای چندین خروجی همزمان با ورودی‌های یکسان به کار برد. در این بخش با در نظر گرفتن دوازده ورودی، یک لایه پنهان و دو نرون در لایه خروجی شبکه عصبی برای برآورد مدل طراحی شده است. با تغییر دادن توابع و تعداد نرون‌های لایه پنهان سعی شد شبکه‌ای که دارای کمترین میانگین خطا بود انتخاب گردد. به همین منظور در برازش مدل‌های شبکه عصبی برای داده‌های فوق‌الذکر از روش یادگیری پس‌انتشار خطا استفاده گردید و برای یافتن بهترین شبکه در حدود ۸۳ نوع شبکه مورد آموزش قرار گرفت. بهترین شبکه‌ای که توانست هر دو متغیر ریسک و ظرفیت اعتباری را با میانگین خطای کمتر برازش نماید از یک شبکه عصبی سه لایه با شش نرون در لایه پنهان و تابع فعال‌سازی تانژانت هیپربولیک تشکیل شده بود. در شکل شماره (۶) شبکه مورد نظر نشان داده شده است.



شکل شماره ۶: شبکه عصبی پرسپترون سه لایه با شش نرون در لایه پنهان و دو خروجی

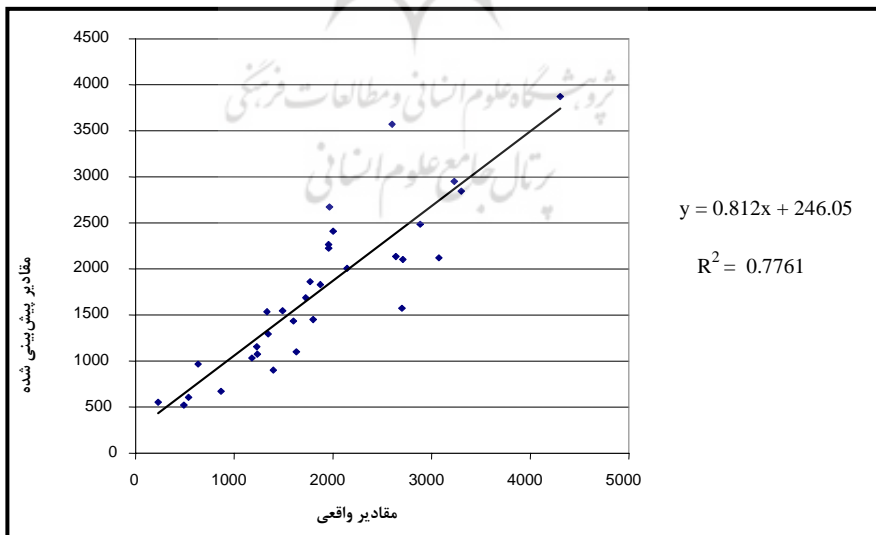
با استفاده از مدل برآورد شده توسط شبکه عصبی، داده‌های آزمایش مورد بررسی قرار گرفت و مقادیر بدست آمده با مقادیر واقعی ریسک و ظرفیت اعتباری مقایسه شدند. که در جدول شماره (۱) نشان داده شده است. همانطور که دیده می‌شود مدل طراحی شده توانسته ۸۴/۳۸٪ ریسک اعتباری مشتریان را درست برآورد نماید. بنابراین شبکه عصبی در برآورد ریسک اعتباری کارایی بالایی دارد. برای نشان دادن کارایی مدل شبکه عصبی در برازش ظرفیت اعتباری، ابتدا داده‌های واقعی و برآورد شده به صورت صعودی مرتب شد و سپس با استفاده از مدل رگرسیون خطی مقدار  $R^2$  محاسبه و نمودار داده‌های واقعی و پیش‌بینی شده همراه با خط رگرسیونی برازش شده رسم گردید. نمودار شماره (۱) نتایج حاصل از این مقایسه را نشان می‌دهد.

جدول شماره ۱): مقایسه مقادیر بدست آمده از شبکه عصبی و داده‌های واقعی

ظرفیت اعتباری مشتریان		ریسک اعتباری مشتریان		ردیف
شبکه عصبی	داده‌های واقعی	شبکه عصبی	داده‌های واقعی	
۲۲۲۴/۵۴	۱۹۵۷	۰	۰/۰۰	۱
۲۰۰۶/۵۶	۲۱۴۴	۰	۰/۰۰	۲
۶۶۹/۹۲	۸۶۷	۱	۱/۰۰	۳
۹۶۵/۶۷	۶۳۴	۱	۱/۰۰	۴
۲۱۰۳/۹۸	۲۷۰۸	۰	۰/۰۰	۵
۱۴۳۴/۳۴	۱۶۰۰	۰	۰/۰۰	۶
۶۰۵/۷۳	۵۳۸	۱	۱/۰۰	۷
۱۰۷۳/۹۲	۱۲۳۵	۱	۱/۰۰	۸
۲۹۵۰/۰۱	۳۲۳۰	۰	۰/۰۰	۹
۲۱۲۰/۷۷	۳۰۷۴	۰	۰/۰۰	۱۰
۳۵۷۱/۷۲	۲۵۹۹	۰	۰/۰۰	۱۱
۱۸۳۱/۱۳	۱۸۷۲	۰	۰/۰۰	۱۲
۵۲۲/۰۵	۴۹۰	۱	۱/۰۰	۱۳
۱۱۵۵/۴۸	۱۲۲۸	۱	۱/۰۰	۱۴
۱۶۸۵/۶۸	۱۷۲۵	۰	۰/۰۰	۱۵
۹۰۰/۸۲	۱۳۹۶	۱	۱/۰۰	۱۶
۲۸۴۴/۵۶	۳۳۰۰	۰	۰/۰۰	۱۷
۱۵۴۶/۸۴	۱۴۸۹	۱	۰/۰۰	۱۸
۱۴۴۹/۷۷	۱۸۰۰	۱	۱/۰۰	۱۹
۱۵۷۴/۰۳	۲۷۰۰	۱	۰/۰۰	۲۰
۱۵۳۴/۷۱	۱۳۳۱	۱	۱/۰۰	۲۱
۱۲۹۳/۱۲	۱۳۴۴	۱	۱/۰۰	۲۲
۵۵۱/۶۶	۲۳۰	۰	۱/۰۰	۲۳
۱۱۰۰/۲۷	۱۶۲۹	۱	۱/۰۰	۲۴

ادامه جدول شماره ۱): مقایسه مقادیر بدست آمده از شبکه عصبی و داده‌های واقعی

ظرفیت اعتباری مشتریان		ریسک اعتباری مشتریان		ردیف
شبکه عصبی	داده‌های واقعی	شبکه عصبی	داده‌های واقعی	
۲۶۷۲/۶۴	۱۹۶۵	۱	۱/۰۰	۲۵
۲۱۳۵/۲۰	۲۶۳۹/۱۳	۱	۰/۰۰	۲۶
۱۸۶۰/۸۳	۱۷۷۰	۱	۱/۰۰	۲۷
۲۴۸۴/۹۰	۲۸۸۴	۰	۰/۰۰	۲۸
۲۴۰۹/۸۰	۲۰۰۲	۰	۰/۰۰	۲۹
۳۸۷۱/۱۸	۴۳۰۵	۱	۰/۰۰	۳۰
۲۲۶۵/۱۴	۱۹۵۶/۳	۰	۰/۰۰	۳۱
۱۰۳۳/۷۴	۱۱۸۰	۱	۱/۰۰	۳۲
٪ ۷۷/۶۱	ضریب تعیین ( $R^2$ )	۲۷	صحیح	
۲۴۶/۰۵	عرض از مبدأ	۵	غلط	
۰/۸۱۲	شیب	٪ ۸۴/۳۸	درصد برآورد صحیح	



نمودار شماره ۱): مقایسه داده‌های مشاهده شده و پیش‌بینی شده با استفاده از شبکه‌های عصبی

همانطور که در نمودار فوق دیده می‌شود کارایی شبکه‌های عصبی در برآورد ظرفیت اعتباری مشتریان بسیار زیاد می‌باشد، شیب  $0/812$  نزدیک به یک بیان‌گر رابطه هم‌گرایی شدید داده‌های برآورد شده با داده‌های مشاهده شده است. از طرف دیگر عرض از مبدا  $246$  نشان‌گر نزدیکی معادله به مبدا مختصات و داشتن کارایی بالا می‌باشد. البته نزدیک بودن نمودار به مبدا مختصات یکی دیگر از فاکتورهای اساسی برای تعیین کارایی به شمار می‌رود. جدول شماره (۲) و (۳) وزن‌های بایاس و ضرایب هرکدام از شاخه‌ها را نشان می‌دهند.

جدول شماره ۲): وزن‌های متغیر بایاس و متغیرهای ورودی از لایه ورودی به لایه پنهان

HiddenLayer No.1						لایه پنهان ۱
Neuron 6	Neuron 5	Neuron 4	Neuron 3	Neuron 2	Neuron 1	
۱/۲۱۷۲	۳/۲۸۱۲	۰/۷۰۲۲	۰/۳۵۶۶	-۲/۹۵۱۹	-۳/۲۲۲۷	Bias
۱/۱۹۰۱	۰/۱۰۴۹	-۳/۷۷۵۶	-۰/۱۴۲۳	-۰/۸۵۹۶	۲/۵۷۹۹	$X_{1KH}$
-۰/۵۶۳۷	-۰/۲۶۴۶	۲/۰۱۷۵	-۰/۰۲۳۱	۰/۲۲۳۸	-۰/۵۶۷۸	$X_{IT}$
۱/۶۲۴۹	-۰/۱۳۱۴	۲/۵۸۰۶	-۰/۵۷۴۲	-۱/۷۹۰۹	-۵/۶۱۷۹	$X_{IB}$
-۲/۳۰۷۶	-۰/۵۸۸۵	۵/۴۱۱۷	-۱/۲۵۱۶	۲/۵۴۳۹	۱/۷۶۹۲	$X_2$
۱/۶۷۹۰	۰/۱۵۹۳	۱/۶۵۵۲	-۰/۱۱۷۶	-۱/۹۰۴۷	-۳/۱۲۸۷	$X_3$
۱/۳۶۴۸	۰/۲۳۷۸	-۱/۸۷۶۴	۱/۳۳۲۲	-۱/۷۷۴۵	-۷/۴۳۱۶	$X_4$
۲/۲۳۸۰	۰/۰۱۹۲	-۲/۲۷۷۸	۰/۲۲۵۶	-۱/۷۳۰۹	-۰/۴۸۴۰	$X_5$
-۰/۹۱۷۳	۴/۴۲۴۷	-۲/۹۳۳۷	-۱/۲۱۸۰	-۲/۵۱۸۳	-۱/۰۳۰۲	$X_6$
-۰/۸۶۰۲	-۰/۰۸۰۵	-۰/۳۵۱۸	-۱/۶۳۴۰	۱/۵۶۲۷	۱/۷۵۳۰	$X_7$
-۰/۹۳۲۱	۰/۳۰۱۹	-۲/۲۶۹۸	۰/۰۱۴۵	۰/۴۱۹۹	-۳/۸۱۸۳	$X_8$
۴/۹۹۵۱	۰/۱۰۸۴	-۱/۲۰۰۶	۰/۲۱۴۷	-۴/۰۱۹۴	-۵/۳۳۷۹	$X_9$
۰/۳۶۶۱	-۰/۰۱۵۶	-۱/۲۶۴۳	۲/۹۶۱۵	۰/۲۵۴۸	-۱/۶۱۹۸	$X_{10}$

جدول شماره ۳): وزن‌های متغیر باباس و نرون‌های لایه پنهان از باباس و لایه پنهان به لایه خروجی

ریسک اعتباری Output 2	ظرفیت اعتباری Output 1		
-۰/۱۷۸۹	-۱/۲۷۷۹	<b>Bias</b>	<b>HiddenLayer No.1</b>
-۰/۰۵۲۶	۱/۳۱۸۸	<b>Neuron 1</b>	
۰/۸۲۹۲	-۰/۲۰۷۹	<b>Neuron 2</b>	
-۰/۲۴۰۷	۰/۰۱۲۰	<b>Neuron 3</b>	
۰/۰۹۱۴	۱/۳۰۴۵	<b>Neuron 4</b>	
۰/۶۴۳۱	۰/۰۲۳۰	<b>Neuron 5</b>	
۰/۸۲۸۰	-۰/۰۰۳۷	<b>Neuron 6</b>	

## نتیجه‌گیری و پیشنهادات

اعطای تسهیلات اعتباری به مشتریان از جمله مهمترین وظایف بانک‌ها به شمار می‌رود. بانک‌ها در هر کشور پس از جمع‌آوری منابع مالی این منابع را به بخش‌های مختلف اقتصادی تخصیص می‌دهند. در حقیقت این اقدام بانک‌ها بخش‌های مختلف اقتصادی را در هر کشور در انجام بهتر وظایف خود تقویت و نهایتاً زمینه لازم را برای رشد و توسعه اقتصادی کشور فراهم می‌آورند. همانطور که در مباحث قبلی بیان شد، در صورتی بانک‌ها می‌توانند به این مهم دست یابند که منابع مالی را به درستی به مشتریان واجد شرایط تخصیص دهند. تخصیص درست منابع مالی ضمن دستیابی به هدف فوق، زمینه لازم را برای ادامه حیات بانک‌ها فراهم خواهد آورد. لیکن در این اقدام نکته حایز اهمیت آنست که، قبل از اعطای تسهیلات، مشتریان واجد شرایط به درستی تشخیص داده شوند، تا اثر بخشی تصمیمات اتخاذ شده ارتقا یابد. بدیهی است اقدام در زمینه کنترل تسهیلات پس از اعطای آن‌ها بی‌فایده خواهد بود. با توجه به این موضوع، بانک‌ها و موسسات مالی برای ارزیابی مشتریان از روش‌های متفاوتی استفاده می‌کنند. برای ارزیابی مشتریان روش‌های قضاوتی از گذشته معمول بوده و حتی در کشور ما هم‌اکنون نیز کاربرد دارد. ولی در حال حاضر این روش کارایی خود را از دست داده است. از این رو در این تحقیق بر آن شدیم که از روش توسعه یافته‌ای، همچون شبکه‌های عصبی علاوه بر روش‌های قضاوتی، تحلیل ممیزی و... برای ارایه مدلی کارا استفاده شود.

ضریب تعیین  $77/61$  درصدی، شیب نزدیک به عدد یک و عرض از مبدا نزدیک به مبدا مختصات برای ظرفیت اعتباری و برآورد صحیح  $84/38$  درصدی ریسک اعتباری در داده‌های آزمون حاکی از کارایی بالای شبکه‌های عصبی است. آنچه که در مجموع می‌توان از این مبحث نتیجه گرفت، این است که استفاده از مدل ریاضی در برآورد ریسک و ظرفیت اعتباری مشتریان قبل از اعطای اعتبار، دارای اهمیت فوق‌العاده‌ای است. لیکن انتخاب مدل مناسب از بین مدل‌های موجود یکی از اساسی‌ترین فاکتورهای اعطای درست اعتبارات است. البته برآورد همزمان ریسک و ظرفیت اعتباری یکی دیگر از مزیت‌های مدل شبکه‌های عصبی نسبت به سایر مدل‌های دیگر است.

## پیشنهادات

به منظور زمینه‌سازی استقرار نظام کارآمد و قابل اتکا برای رتبه‌بندی اعتباری در کشور، و ارزیابی هر چه بهتر مشتریان لازم است که اقداماتی در جهت رفع موانع موجود بر سر راه تخصیص درست اعتبارات صورت پذیرد. در این راستا، پیشنهادهای به شرح زیر ارایه می‌شود که

تحقق آن‌ها پیش شرط ایجاد یک نظام مستحکم، دقیق و جامع رتبه‌بندی اعتباری در بانک‌ها و موسسات مالی خواهد بود.

- طراحی نرم‌افزار جهت به کارگیری مدل شبکه‌های عصبی در بانک‌های کشور؛
- طراحی سیستم استانداردسازی فرایندهای اعتباری به منظور کنترل جنبه‌های سخت‌افزاری؛
- ایجاد بانک اطلاعاتی در بانک‌ها و موسسات مالی به منظور جمع‌آوری، ذخیره‌سازی و روزآمدسازی اطلاعات مالی و اعتباری مشتریان؛
- ملزم کردن شرکت‌های متقاضی اعتبار به ارائه صورت‌های مالی شرکت (که توسط حسابرس مستقل حسابرسی شده‌اند) به بانک‌ها و موسسات مالی؛
- هدایت شرکت‌های بزرگ و به خصوص آن‌هایی که فعالیت‌های بین‌المللی دارند به سوی رتبه‌بندی شدن توسط موسسات اعتبارسنجی معتبر بین‌المللی؛
- عهدار شدن بانک مرکزی برای جمع‌آوری اطلاعات اعتباری همه بانک‌ها و به اشتراک گذاشتن اطلاعات در شبکه اطلاعات بانکی به منظور استفاده تمامی شعب بانک‌ها از این پایگاه؛
- تنظیم و طراحی مدل کارآمد ارزیابی مشتریان، جهت استفاده تمامی شعب بانک‌ها و موسسات مالی؛
- آموزش پرسنل جهت استفاده از مدل و سیستم تخصیص اعتبارات؛
- بازنگری و روزآمد کردن مدل‌های شبکه عصبی با اعلام اطلاعات مالی جدید مشتریان در هر سال مالی.



### فهرست منابع

- ۱- منصورى، على و عادل، آذر (۱۳۸۱) طراحی و تبیین مدل کارآمد تخصیص تسهیلات بانکی- رویکرد شبکه‌های عصبی، رگرسیون لجستیک و خطی، مجله علمی پژوهشی دانشگاه تربیت مدرس.
- ۲- مشیری، سعید و قدیمی، محمدرضا (۱۳۸۱) مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی، فصلنامه پژوهش‌های اقتصادی ایران.
- ۳- منہاج، محمداقبر (۱۳۷۹) مبانی شبکه‌های عصبی، دانشگاه صنعتی امیرکبیر، مرکز نشر پروفیسور حسابی.
- 4- Beaver W., 1967, "Financial Ratio as Predictor of Failures", Journal of Accounting Research 4(Suppl.).
- 5- Bernard Windrow and Marlin E. 1960, Hoff, "Adaptive Switching Circuits", IRE Part 4 WeSCON Report, N. Y.
- 6- Cudill, M. (ED), 1995, "Using Neural Networks: AI Expert".
- 7- David J. Cavuto, 1997, "an Exploration and Development of Current Artificial Neural Network Theory and Applications with Emphasis on Artificial Life", A Thesis Submitted in Partial Fulfillment of the Requirements for the Degree of Master of Engineering, May 6.
- 8- Deakins E. B., 1972, "A Discriminate Analysis of Predictors of Business Failure", Journal of Accounting Research 10(1).
- 9- Donald O. Hebb, 1949, "The Organization of Behavior", Wiley, N. Y.
- 10- Edward I. Altman, 1968, "Financial Ratios, Discriminant Analysis and The Prediction of corporate Bankruptcy", vol. 22, September.
- 11- Frank Rosenblatt, 1958, "The Perceptron: A Probabilistic model for Information Storage and Organization in the Brain", Psychological Review, vol. 65.
- 12- Hayking, S., Neural Networks, 1994,: A Comprehensive Function, Macmillan, New York.
- 13- James Anderson, 1972, "A Simple Neural Network Generating an Interactive Memory", Mathematical Bioscience, vol. 14.
- 14- Jason E. Kutsurelis, 1991, "Forecasting Financial Markets Using Neural Networks: an Analysis of Methods and Accuracy", United States Navy B.S., United States Naval Academy, Master of Science in Management.
- 15- Robert J. Schalkoff, 1997, "Artificial neural Networks", McGraw Hill.

- 16- S. Grossberg, 1988, "How Does the Brain Build Cognitive Code?", Psychology Review, vol. 88.
- 17- Surkan, A. And J. Singleton, 1990, "Neural Networks for Bond Rating Improved by Multiple Hidden Layers," Proceedings of the 1990 International Joint Conference on Neural Networks, 4.
- 18- Teo Kohonen, 1972, "Correlation Matrix Memories", IEEE Trance on Comp., vol. 21.
- 19- W. McCulloch and W. Pitts, 1943, "A Logical calculus of the Ideas Immanent in Nervous Activity", Bulletined of Mathematical Biophysics, vol. 5.

