

ارزیابی ریسک حسابرسی با استفاده از رویکرد داده کاوی مبتنی بر شبکه عصبی در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران

تاریخ دریافت: ۱۴۰۰/۲/۲۶

تاریخ پذیرش: ۱۴۰۱/۱/۳۱

داود همتی^۱

مهدی عرب‌صالحی نصرآبادی^۲

عباس طلوعی اشلقی^۳

چکیده:

برنامه‌ریزی حسابرسی با ارزیابی ریسک حسابرسی همراه است. هدف از اجرای این پژوهش ارزیابی ریسک حسابرسی با استفاده از رویکرد داده کاوی مبتنی بر شبکه‌های عصبی در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران طی سالهای ۱۳۹۶ تا ۱۳۹۸ بوده است که بر اساس داده‌های گرفته شده از ۹۰ شرکت می‌باشد. جهت مرتب‌سازی داده‌ها از نرم افزار اکسل و برای تجزیه و تحلیل یافته‌های پژوهش و کد نویسی هر یک از الگوریتم‌های مورد استفاده از نرم افزار متلب استفاده گردیده است. جهت ارزیابی ریسک حسابرسی، از طریق دو الگوی شبکه عصبی به ارزیابی قدرت هر کدام از الگوها پرداخته شد. در این پژوهش ابتدا از روش شبکه عصبی مصنوعی و سپس ترکیب آن با الگوریتم بهینه سازی اجتماع ذرات استفاده گردید. در ادامه به منظور مقایسه نتایج پیش‌بینی از میانگین درصد خطا، میانگین قدر مطلق خطا، مجذور میانگین مربعات خطا و ضریب همبستگی استفاده شد. نتایج پژوهش نشان داد الگوی ترکیبی قدرت پیش‌بینی بالاتری دارد.

کلمات کلیدی: ریسک حسابرسی، داده کاوی، شبکه‌های عصبی

۱. دانشجوی دکتری حسابداری، دانشگاه آزاد اسلامی واحد اصفهان (خوراسگان)، اصفهان، ایران.

۲. دانشیار حسابداری، دانشگاه اصفهان، اصفهان، ایران. نویسنده مسئول. ایمیل:

mehdi_arabsalehi@ase.ui.ac.ir

۳. استاد مدیریت صنعتی، دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران، تهران، ایران.

۱. مقدمه

شرایط پر رقابت امروز و شکست‌های گسترده تجاری سبب بالا رفتن مسئولیت حسابرسان در حسابرسی صورتهای مالی شرکتها و به خصوص شرکتهای پذیرفته شده در بورس اوراق بهادار تهران شده است. این مسئولیت تا جایی پیش رفته که اشتباهات حسابرسان سبب ایجاد دعاوی حقوقی علیه آنان شده است. دعاوی مربوطه به مرور از اعتبار حسابرسان در جامعه حرفه‌ای خواهد کاست. از اینرو حسابرسان در هنگام برنامه‌ریزی حسابرسی در شرکتهای بورسی که مالکان متنوعی دارد، باید دقت نظر بالایی همراه با تردید حرفه‌ای اعمال نمایند. از جمله مهم‌ترین مواردی که سبب بالا رفتن دقت حسابرسی خواهد شد، ارزیابی مناسب و دقیق ریسک حسابرسی است. هر چه دقت ارزیابی ریسک حسابرسی بالاتر باشد احتمال اظهار نظر درست حسابرس افزایش خواهد یافت. بالا رفتن دقت ارزیابی ریسک حسابرسی مستلزم قضاوت‌های حرفه‌ای‌تر حسابرسان است که این مسئله مستلزم استفاده از ابزارهای نوین و دقیق‌تر در جهت ارزیابی ریسک حسابرسی می‌باشد (فونگ تائو^۱ و همکاران، ۲۰۱۹؛ بل و همکاران^۲، ۲۰۰۵؛ قربانی و همکاران^۳، ۱۳۹۳؛ کمیته تجدید نظر دستورالعمل حسابرسی، ۱۳۹۸).

پژوهش‌های قبلی نشان داده که داده کاوی یکی از ابزارهایی است که در اندازه‌گیری مواردی همچون ریسک حسابرسی دقت و سرعت بالایی دارد (ژانگ^۴، ۲۰۲۱؛ هو پینگ^۵، ۲۰۲۱؛ چارلز و همکاران^۶، ۲۰۱۶؛ چن و هانگ^۷، ۲۰۱۱). رویکرد داده کاوی، ایده‌ای است برای پردازش اطلاعات که از سیستم‌های عصبی موجودات زنده الهام گرفته است. با اینکه از ساخت اولین سلول عصبی در نیمه قرن بیستم میلادی زمان زیادی می‌گذرد، ولی تا دهه اخیر، استفاده از ساختار خاص حل مساله توسط شبکه عصبی، عمومیت نیافته است. قابلیت هیجان انگیز این ایده در استنتاج معانی مبهم و پیچیده و در نتیجه، درک و شناسایی الگوها و حل مسئله، این ابزار را به روشی محبوب برای اندازه‌گیری تبدیل کرده است (چن و هانگ^۸، ۲۰۱۱؛ طلوعی اشلقی و همکاران^۹، ۱۳۸۹). اهمیت و توسعه کاربرد داده کاوی در تجارت، اقتصاد، تصمیم‌گیری و حسابرسی موجب گردید که شرکتهای زیادی در این حوزه به فعالیت بپردازند و محصولات سخت‌افزاری و نرم افزارهای متعدد، متنوع و پیشرفته با رویکردها و ساختارهای متفاوتی به بازار عرضه کنند. در این شرایط، علم داده کاوی ابزاری سودمند است که در اختیار تمامی سازمان‌ها و شرکتها و از جمله موسسات حسابرسی می‌باشد (ژانگ^{۱۰}، ۲۰۲۱؛ هو پینگ^{۱۱}، ۲۰۲۱؛ جفری و شفریت^{۱۲}، ۲۰۰۴).

علم داده کاوی امروز در افزایش دقت پیش‌بینی‌ها بسیار ضروری است، زیرا تا حد زیادی از خطاهای انسانی جلوگیری می‌کند. گرچه ارزیابی ریسک حسابرسی یک مسئله قضاوتی است، اما

1. Phuong Thao
2. Bell et al.
3. Zhang
4. Hua-Ping
5. Charles et al.
6. Chen & Huang
7. Jeffrey & Seifert

استفاده از رویکرد داده کاوی به عنوان یک ابزار اندازه‌گیری سبب قضاوت دقیق‌تری خواهد شد. به خصوص اینکه امروزه حسابرسان با افزایش شدید حجم معاملات و پیچیدگی‌های داده‌های مالی و غیر مالی صاحبکارشان روبه‌رو شده‌اند. در نتیجه، حسابرسان بیش از این نمی‌توانند تنها به ابزارهای گزارشگری یا خلاصه کردن در فرآیند متکی باشند. اینجاست که استفاده از ابزارهای داده کاوی همچون شبکه‌های عصبی که بطور خودکار اطلاعات را از میان حجم داده‌های زیاد، استخراج می‌کنند، بسیار ضروری می‌شوند. با اندازه‌گیری دقیق و سریع ریسک حساسی در واحدهای مورد رسیدگی کار حساسی راحت‌تر و دقیق‌تر پیش می‌رود. سازمان حساسی در نشریه ۱۵۰ دستورالعمل حساسی مبتنی بر ریسک را انتشار داده که دارای پیچیدگی‌هایی می‌باشد و دارای فرآیندی طولانی می‌باشد. حال اگر بتوان مدل ریسک حساسی را با داده کاوی به شکل دقیق‌تری برنامه‌ریزی کرد بر دقت و سرعت کار حسابرسان افزوده می‌شود که با توجه به نیاز آنها در زمینه‌های مذکور دارای اهمیت فراوانی است؛ یعنی ایجاد یک برنامه کامپیوتری که بتواند در هر بار تنها با وارد نمودن داده‌های واحد مورد رسیدگی میزان ریسک را اندازه‌گیری نماید، بسیار ارزشمند و ضروری است (ژانگ، ۲۰۲۱؛ هوپینگ، ۲۰۲۱؛ سابائو^۱ و همکاران، ۲۰۱۱؛ چانگ و همکاران^۲، ۲۰۰۸؛ وانگ و یانگ^۳، ۲۰۰۷؛ کرکوس^۴ و همکاران، ۲۰۰۷؛ کالدرن^۵ و همکاران، ۲۰۰۲؛ دستگیر و شفیعی، ۱۳۹۰؛ وکیلی فرد و صلاحی نژاد، ۱۳۸۸).

با توجه به موارد مطروحه هدف از این پژوهش ارزیابی ریسک حساسی با استفاده از رویکرد داده کاوی مبتنی بر شبکه‌های عصبی در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است؛ که بدین منظور علاوه بر شبکه‌های عصبی از ترکیب آن با الگوریتم بهینه‌سازی اجتماع ذرات نیز در جهت بررسی‌های دقیق‌تر و جدیدتر استفاده می‌شود، لذا نوآوری موضوعی مرتبط با ارزیابی ریسک با استفاده از الگوهای شبکه عصبی جدید است. از لحاظ نوآوری مکانی نیز کمتر تحقیقی به ارزیابی ریسک حساسی با استفاده از روش‌های شبکه عصبی در شرکت‌های پذیرفته شده در بازار سرمایه ایران پرداخته است. روش تحقیق نیز با توجه به دقت بالای شبکه‌های عصبی سبب اندازه‌گیری دقیق‌تر ریسک حساسی خواهد شد.

با توضیحات فوق بررسی توان داده کاوی در ارزیابی ریسک حساسی توسط نهادهای حساسی در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران در جهت دستیابی به اهداف پژوهش مسئله اصلی این پژوهش است که برای حل این مسئله به سوالات زیر پاسخ داده می‌شود:

۱. آیا الگوی شبکه عصبی (پرسپترون چند لایه^۶) از توانایی لازم برای ارزیابی ریسک حساسی برخوردار است؟

- 1.. sabau
2. Chang et al
3. Wang & Yang
- 4.. Kirkos et al
- 5.. Calderon et al
6. . Multilayer perceptron (MLP)

۲. آیا الگوی شبکه عصبی فرا ابتکاری (ترکیب شبکه عصبی با الگوریتم بهینه‌سازی اجتماع ذرات^۱) از توانایی لازم برای ارزیابی ریسک حساسیتی برخوردار است؟
 ۳. آیا دقت الگوی شبکه عصبی فرا ابتکاری (ترکیب شبکه عصبی با الگوریتم بهینه‌سازی اجتماع ذرات) جهت ارزیابی ریسک حساسیتی از الگوی شبکه عصبی (پرسپترون چند لایه) بیشتر است؟

در ادامه این مقاله ابتدا مبانی نظری و تجربی پژوهش ارائه می‌شود و بعد از بیان روش شناسی پژوهش و الگوی پژوهش به بیان یافته‌ها و بحث و نتیجه‌گیری پرداخته می‌شود.

۲. مبانی نظری پژوهش

حسابرسی روز به روز در حال تکامل است. این فرآیند تکامل، در واقع فرآیند سازگاری با نیازهای جوامع در حال پیشرفت است که با توسعه فعالیت‌های تجاری و صنعتی صورت گرفته است. در این مسیر تکاملی چهار نحوه عمل کلی حساسیتی مبتنی بر سندرسی، حساسیتی ترازنامه، حساسیتی مبتنی بر سیستم و حساسیتی مبتنی بر ریسک وجود دارد، که در پاسخ به شکست‌های گسترده تجاری در سراسر دنیا، حساسیتی مبتنی بر ریسک به عنوان رویکرد غالب در سال‌های اخیر برای مبارزه با فساد مطرح بوده است (فونگ تائو^۲ و همکاران، ۲۰۱۹).

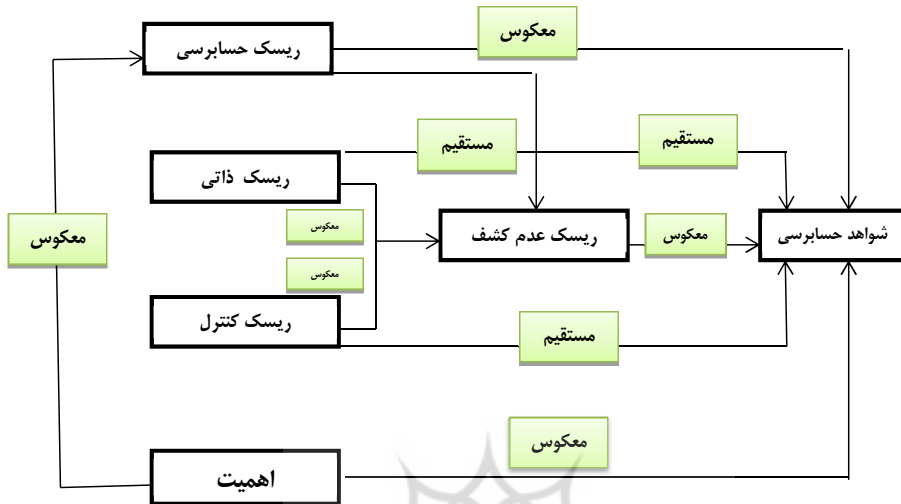
حسابرسی مبتنی بر ریسک از سال ۱۹۹۰ توسط شرکت‌های حساسیتی بزرگ مورد استفاده قرار گرفت. انجمن‌های حرفه‌ای طی ۱۳ سال از سال ۱۹۹۰ تا ۲۰۰۳ در خصوص ریسک حساسیتی بررسی‌هایی انجام دادند. در نهایت از سال ۲۰۰۳ سه استاندارد بین‌المللی حساسیتی شامل استاندارد ۳۱۵ تحت عنوان شناخت واحد تجاری و محیط آن و برآورد ریسک تحریف با اهمیت، استاندارد ۳۳۰ تحت عنوان رویه‌های حساسیت در برخورد با ریسک‌های برآوردی و استاندارد ۵۰۰ تحت عنوان شواهد حساسیتی منتشر گردید. این استانداردها در ایران نیز با شماره‌های ۵-۳۱، ۳۳ و ۵۰ مطرح گردیدند (برزیده و نیکخواه بهرامی، ۱۳۸۶).

با افزایش استانداردهای حساسیتی مرتبط با ریسک حساسیتی امروزه رویکرد غالب حساسیتی مبتنی بر ریسک می‌باشد و از اینرو یکی از مهم‌ترین مواردی است که حسابرس در هنگام برنامه‌ریزی حساسیتی باید مورد توجه قرار دهد، ارزیابی ریسک حساسیتی است. ریسک حساسیتی یک مدل حساسیتی است که باید در تمامی مراحل حساسیتی از برنامه‌ریزی گرفته تا جمع‌آوری شواهد و ارائه گزارش نهایی مورد توجه قرار گیرد (ریبوعی و همکاران، ۱۳۹۷). ریسک حساسیتی دارای ارتباط تنگاتنگی با سایر اجزای حساسیتی است که شکل (۱) این موضوع را به وضوح نشان می‌دهد:

1. Particle Swarm optimization (PSO)

2.. Phuong Thao

شکل ۱: ارتباط بین اجزای مدل ریسک حسابرسی، اهمیت و شواهد حسابرسی (منبع: چانگ و همکاران، ۲۰۰۸)



دقت در شکل فوق نشان می‌دهد که مدل ریسک حسابرسی از عوامل زیادی تأثیر می‌پذیرد و بر عوامل زیادی هم اثرگذار است. جهت اندازه‌گیری ریسک حسابرسی با برآورد میزان ریسک عدم کشف و ریسک ذاتی و ریسک کنترل میزان ریسک حسابرسی با توجه به مدل زیر مشخص می‌شود:

$$AR = IR \times CR \times AP \times TD$$

که در آن AR ریسک پذیرفته شده حسابرسی و IR ریسک ذاتی و CR ریسک کنترل و AP ریسک عدم موفقیت روش‌های بررسی تحلیلی در کشف تحریف با اهمیت و TD ریسک عدم موفقیت آزمون‌های محتوا در کشف تحریفی با اهمیت که واقع شده و توسط سیستم کنترل داخلی کشف نشده است، می‌باشند (چانگ و همکاران، ۲۰۰۸).

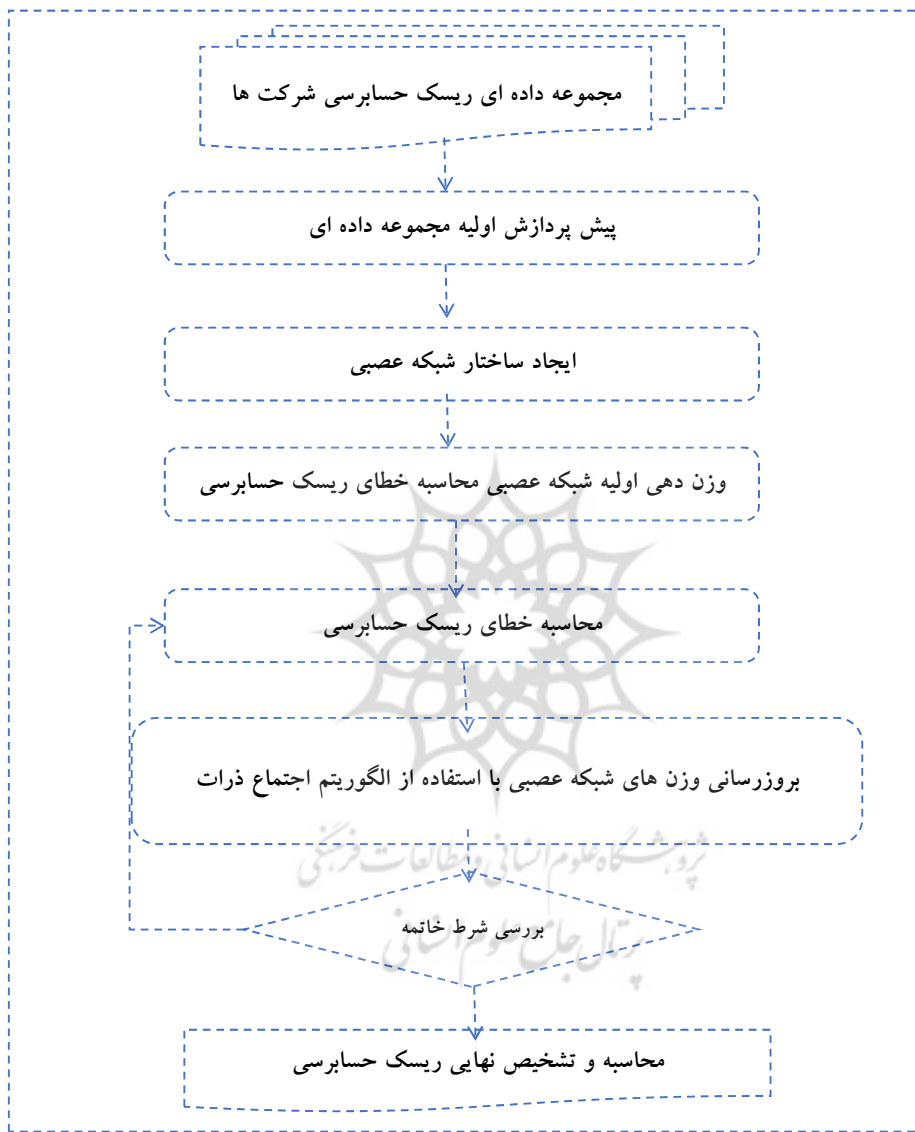
هر یک از اجزای ریسک حسابرسی دارای زیر مولفه‌هایی است که بسته به نوع فعالیت شرکت باید شناسایی و میزان ریسک در نهایت بر اساس قضاوت حسابرس برآورد گردد. برخی شرکت‌های بزرگ به دلیل انبوه کارها از تکنیک‌های داده کاوی برای برآورد ریسک حسابرسی استفاده می‌کنند. انگیزه برای گسترش داده کاوی بطور عمده از دنیای تجارت در دهه ۱۹۹۰ پدید آمد. داده کاوی در حال حاضر یکی از مهمترین ابزارهای موجود در حوزه هوش تجاری است. حسابداری و حسابرسی نیز بیش از سه دهه است که از این تکنیک‌ها استفاده کرده است (ژانگ،

۲۰۲۱؛ هو پینگ، ۲۰۲۱؛ بالدون^۱ و همکاران، ۲۰۰۶). حسابداری یکی از اولین حوزه‌های تجاری بوده که از روشهای داده کاوی برای بهبود تصمیم‌گیری استفاده کرده است (امانی و فادلالا^۲، ۲۰۱۷). داده کاوی بعنوان فرآیند تشخیص الگوهای صحیح، نوین و غیر قابل درک (توسط انسان) از مجموعه بزرگی از داده‌ها و همچنین بعنوان روشی برای استخراج دانش از داخل انبوهی از داده‌ها تعریف شده است (هان و همکاران^۳، ۲۰۰۶). داده کاوی مجموعه‌ای از تکنیک‌های کمک‌های کامپیوتری است که به صورت خودکار برای جمع‌آوری داده‌های یکپارچه برای اطلاعات جدید، پنهان یا غیر منتظره یا الگوها به طور اتوماتیک به کار می‌روند. داده کاوی گاهی اوقات به عنوان کشف دانش در پایگاه‌های داده شناخته می‌شود. در سال‌های اخیر، تکنولوژی پایگاه داده در حال پیشرفت است (سیریک الوادهانا^۴، ۲۰۰۲).

داده کاوی شامل مجموعه‌ای از تکنیک‌هایی است که در حوزه‌های دیگر علمی مانند پایگاه داده‌ها، آمار، یادگیری ماشین، شبکه‌های عصبی، بازیابی اطلاعات و تشخیص الگو می‌توان آن را یافت (اسماعیلی، ۱۳۹۱). در حوزه حسابداری و امور مالی بسیاری از پیش‌بینی‌ها از الگوهای خطی ساده پیروی نمی‌کنند، بلکه بر اساس سیستمی غیر خطی و آشوب‌گونه تحت تاثیر شرایط سیاسی، اقتصادی، روانشناسی و غیره می‌باشد، دچار تغییر می‌شوند. بهترین روش جهت پیش‌بینی مواردی با این ویژگی‌ها استفاده از سیستم‌های هوشمند غیر خطی است. امروز هوش مصنوعی در راستای پیش‌بینی چنین مواردی همچون دستکاری مدیریت در داده‌های حسابداری بسیار مورد توجه است. می‌توان گفت مهمترین کاربرد سیستم‌های هوشمند در حسابداری، مدیریت و اقتصاد، پیش‌بینی متغیرها است (فروغی و یادگاری، ۱۳۸۹). یکی از سیستم‌های مبتنی بر هوش مصنوعی جهت انتخاب بهترین اطلاعات و اتخاذ تصمیم منطقی بر اساس اطلاعات انتخاب شده و همچنین برای انجام پیش‌بینی در شرایط پیچیده و غیر خطی، روش‌های هوشمند ترکیبی، شبکه‌های عصبی مصنوعی و الگوریتم‌های فرا ابتکاری می‌باشد (مطیع قادر و همکاران، ۱۳۸۹). بر اساس مبانی مطرحه الگوی کلی محاسبه برآورد ریسک حسابداری با استفاده از رویکرد داده کاوی به شرح ذیل است:

1. Baldwin et al
2. Amani & Fadlalla
3. Han et al
4. Sirikalvadhana

شکل ۲: الگوی مفهومی پژوهش



منبع: (هوپینگ، ۲۰۲۱؛ فونگ تائو و همکاران، ۲۰۱۹؛ پراساد و همکاران، ۲۰۱۸)

۳. پیشینه تجربی پژوهش

ژانگ (۲۰۲۱) در پژوهشی با عنوان ساخت و شبیه‌سازی مدل حسابرسی مالی بر اساس شبکه عصبی متحرک در شرکت‌های چینی به تجزیه و تحلیل داده‌های چند بعدی و هوشمند و توسعه موارد حسابرسی داده‌های بزرگ با استفاده از الگوریتم ژنتیک برای بهینه‌سازی مدل شبکه عصبی پرداخت. نتایج نشان داد که میزان خطای تشخیص مدل شبکه عصبی با بهبود الگوریتم نرخ یادگیری در مجموعه داده‌های حسابرسی مالی کمتر از شبکه پیشخوان چند لایه است و عملکرد بهتری دارد؛ طوریکه شبکه‌های عصبی متحرک می‌توانند برآوردهای دقیق‌تری ارائه نمایند. هو پینگ (۲۰۲۱) به انجام پژوهشی با عنوان پیش‌بینی گزارشات حسابرسی شرکتها با شبکه‌های عصبی پس انتشار^۱ پرداخته است. هدف اصلی این پژوهش ارتباط دادن خطر تحریف با اهمیت با انواع گزارشات حسابرسی در مورد صورتهای مالی شرکتها برای تصمیم‌گیری بهتر در زمینه کار حسابرسی است. در این پژوهش یک مدل پیش‌بینی گزارش حسابرسی برگرفته از شبکه عصبی پس انتشار با استفاده از ۱۴ مجموعه داده‌های مالی خام شرکت‌های موجود در صنعت خرده فروشی و عمده فروشی در بورس اوراق بهادار چین تست شده است. نتایج نشان می‌دهد که دقت پیش‌بینی مدل شبکه عصبی پس انتشار بالا است. وی روبکا^۲ (۲۰۲۰) به بررسی استفاده از مدل‌های یادگیری ماشین و هوش مصنوعی برای تجزیه و تحلیل صورتهای مالی سالانه برای شناسایی شرکت‌های متقلب در کشور لهستان پرداخته و هدف اصلی این پژوهش ارائه مدلی جهت شناسایی شرکت‌های متقلب و غیر متقلب با استفاده از روشهای هوش مصنوعی می‌باشد. نتایج پژوهش نشان داد که الگوریتم‌های یادگیری ماشین و هوش مصنوعی قادر به یادگیری تشخیص الگوهای تقلب بوده و می‌توانند آنها را به طور موثر شناسایی کنند. فونگ تائو و همکاران (۲۰۱۹) به بررسی تشخیص ریسک حسابرسی با استفاده از شبکه عصبی پرداختند. داده‌های مورد استفاده در این پژوهش از طریق انجام یک نظر سنجی برای ۳۵ پروژه در ویتنام صورت گرفته تا به این نتیجه برسند که آیا سیستم کنترل داخلی روند درستی را دنبال می‌کند یا خیر؟ که در این بررسی برای ارزیابی ریسک کنترل از ۴۶ معیار استفاده شده است. ۷۰ درصد داده‌ها بعنوان داده آموزشی و ۳۰ درصد بعنوان داده تست مورد استفاده قرار گرفته است. نتایج نشان داد ساختار شبکه عصبی با سطح دقت و سرعت بالا می‌تواند برای شناسایی ریسک حسابرسی مورد استفاده قرار گیرد. آیلا^۳ (۲۰۱۷) به بررسی ارزیابی باز پرداختهای مالی با استفاده از روشهای داده‌کاوی پرداخته که در این پژوهش مدل‌های پیش‌بینی را بر اساس مجموعه داده واقعی ۳۵۱۳ مورد طی دوره زمانی ۲۰۱۴-۲۰۰۱ و همچنین دوره‌های قبل و بعد از بحران مالی سال ۲۰۰۸ در کانادا مورد بررسی قرار داده و روش پژوهش با استفاده از فرایند استاندارد صنعت متقابل برای داده‌کاوی^۴ می‌باشد که شامل مرحله جمع‌آوری داده، پیش پردازش داده، ساخت مدل با استفاده از شبکه عصبی

1. Back Propagation
2. Wyrobeka
3. Ila
4. Cross-industry standard process for data mining (CRISP - DM)

مصنوعی، درخت تصمیم‌گیری، شبکه بیزی، الگوریتم طبقه‌بندی ماشین بردار و در نهایت ارزیابی مدل می‌باشد. نتایج نشان می‌دهد برای هر دو دوره قبل و بعد از بحران کاملاً سازگار است و از بین روشهای مورد استفاده شبکه‌های عصبی نتیجه دقیق‌تری (دقت پیش‌بینی کنندگی ۸۳ درصد) را نشان می‌دهد. همتی و همکاران (۱۳۹۹) پژوهشی با عنوان ارزیابی ریسک حساسیتی با استفاده از رویکرد داده کاوی (مطالعه موردی: تسهیلات بانکی) انجام دادند. هدف از اجرای این پژوهش ارزیابی ریسک حساسیتی اعتباری با استفاده از رویکرد داده کاوی در بانک‌های پذیرفته شده در بورس اوراق بهادار تهران طی سال ۱۳۹۶ بوده است که بر اساس داده‌های گرفته شده از ۲۰۰ نفر از کسانی است که از بانک تسهیلات گرفته‌اند. متغیرهای ورودی مهم معرفی شده به شبکه عصبی فیدفرورد شامل دریافتی‌های سالانه، حساب جاری، خانه، کار، سابقه کاری، افراد تحت تکفل و وضعیت دفترچه چک است. یافته‌ها نشان داد که تکنیک داده کاوی دارای دقتی حدود ۹۷ درصد می‌باشد. مسیحی و همکاران (۱۳۹۸) پژوهشی در رابطه با استفاده از تکنیک‌های داده کاوی برای سنجش ریسک مالیاتی مؤدیان مالیات بر ارزش افزوده پرداختند. به منظور ارزیابی ریسک مالیاتی از دو تکنیک داده کاوی ماشین بردار پشتیبان و رگرسیون لجستیک استفاده شده است. جامعه آماری پژوهش شامل اشخاص حقوقی بزرگ در شهر تهران می‌باشد که در دوره سه ساله از سال ۱۳۹۱ تا سال ۱۳۹۳ مورد حساسیتی مالیاتی در نظام مالیات بر ارزش افزوده قرار گرفته‌اند. در این پژوهش متغیرهای مورد استفاده شامل ساز و کارهای حاکمیت شرکتی، ویژگی‌های خاص شرکتی، ماهیت فعالیت مؤدیان سیستم کنترلی مؤدیان و نسبت‌های مالی می‌باشد که به منظور آموزش و آزمون مدل استفاده شده‌اند. نتایج پژوهش نشان می‌دهد دو تکنیک ماشین بردار پشتیبان و رگرسیون لجستیک از توان صحت ارزیابی ۷۰٪ برخوردار هستند.

۴. روش‌شناسی پژوهش

این پژوهش کاربردی بوده و مبتنی بر تحقیقات کتابخانه‌ای است، یعنی بر مبنای اطلاعات مرتبط با اجزای ریسک حساسیتی شرکت‌های بورسی جمع‌آوری شده و سوالات پژوهش پاسخ داده می‌شوند و سپس نتایج حاصله به کل جامعه آماری تعمیم داده می‌شود. جامعه آماری این پژوهش شامل شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است. بدین منظور تعداد ۹۰ شرکت موجود در جامعه آماری با اولویت در دسترس بودن اطلاعات مالی و ریسک حساسیتی در سالهای مالی ۱۳۹۸-۱۳۹۶ به عنوان نمونه آماری انتخاب شدند. روش پژوهش از نظر روش شناختی، تحلیلی است، زیرا نظریه‌ها، قوانین و اصول و تکنیک‌های یک شبکه عصبی برای پیش‌بینی ریسک حساسیتی استفاده می‌شود. در همین راستا از یک سیستم هوشمند ترکیبی مبتنی بر شبکه عصبی و الگوریتم بهینه‌سازی ذرات استفاده می‌شود که خروجی زیر سیستم‌های استفاده شده را با یکدیگر ترکیب نموده و یک خروجی واحد ارائه می‌نماید. در واقع، در این پژوهش با استفاده از یک برنامه مبتنی بر شبکه‌های عصبی و با رویکرد داده کاوی مدلی برای اندازه‌گیری ریسک حساسیتی ارائه می‌شود. جهت اندازه‌گیری هر یک از عوامل ریسک حساسیتی به صورت نمونه‌ای

پاره ای از موارد ارائه می‌شود:

جدول ۱: برآورد ریسک عدم کشف ناشی از بررسی تحلیل مقدماتی (AP) (کمیته تجدید نظر دستورالعمل حسابرسی، ۱۳۹۸)

مولفه	سال قبل (۱)	سال جاری (۲)	تفاوت سال جاری نسبت به سال قبل (۳)	درصد تغییر (۴)	درصد ریسک (۵)
نسبت جاری					
دوره وصول مطالبات					
دوره گردش کالا					
نسبت مالکانه					

حال با توجه به میزان درصد تغییر میزان ریسک هر یک از موارد به شرح زیر مشخص می‌شوند:

ریسک ناشی از انحراف‌های (تا ۵٪)، (۶ تا ۲۰٪)، (۱ تا ۵۰٪) و (بیش از ۵۰٪) به ترتیب معادل ۶۰٪، ۷۵٪، ۹۰٪ و ۱۰۰٪ در نظر گرفته می‌شود.

جدول ۲: نحوه برآورد ریسک ذاتی در سطح صورتهای مالی (کمیته تجدید نظر دستورالعمل حسابرسی، ۱۳۹۸)

مولفه	ضریب پیشنهادی (۱)	ضریب تایید شده (۲)	ریسک (بین ۵۰ تا ۱۰۰ درصد) (۳)	نتیجه (۳×۲)
روش اداره واحد مورد رسیدگی				
درستکاری و حسن شهرت مدیریت				
تجربه و دانش مدیریت				
تغییرات مدیریت				

جدول ۳: نحوه برآورد ریسک ذاتی در سطح مانده حساب (کمیته تجدید نظر دستورالعمل حسابرسی، ۱۳۹۸)

مولفه	ضریب پیشنهادی	میزان هر حساب
دارایی ثابت منقول	۵۰٪	
دارایی ثابت غیر منقول	۶۰٪	
بستانکاران تجاری	۶۰٪	
حقوق و دستمزد	۶۵٪	

میزان هر حساب	ضریب پیشنهادی	مولفه
	٪۷۰	موجودی مواد و کالا
	٪۷۰	بدهکاران تجاری
	٪۷۰	فروش
	٪۷۰	سایر هزینه‌ها
	٪۷۵	مصرف مواد
	٪۸۰	خرید
	٪۱۰۰	موجودی نقد

جدول ۴: نحوه برآورد ریسک (کمیته تجدید نظر دستورالعمل حساسیتی، ۱۳۹۸)

ضریب پیشنهادی	مولفه
بر اساس مولفه‌های پنج گانه کنترل داخلی شامل محیط کنترلی، فعالیت‌های کنترلی، ارزیابی ریسک، اطلاعات و ارتباطات و نظارت ارزیابی می‌شوند.	چرخه فروش، درآمدها و دریافت‌ها
	چرخه خرید، هزینه‌ها و پرداخت‌ها
	چرخه حقوق و دستمزد
	چرخه دارایی‌های ثابت
	چرخه موجودی مواد و کالا

پس از مشخص نمودن ریسک قابل پذیرش حساسیتی در هر صنعت TD ریسک عدم موفقیت آزمون‌های محتوا اندازه گیری می‌شود. برای مثال دامنه ریسک قابل پذیرش حساسیتی در بانک‌ها بین ۵ تا ۸٪ و شرکت‌های خصوصی بین ۹ تا ۱۳ درصد در نظر گرفته شده‌اند (کمیته تجدید نظر دستورالعمل حساسیتی، ۱۳۹۸).

۵. الگوی پژوهش

این پژوهش تلاش دارد ضمن معرفی متغیرهای موثر و بهینه نسبت به ارائه یک الگو در ارزیابی ریسک حساسیتی بر اساس الگوهای غیر خطی در شرکت‌های پذیرفته شده در بورس اوراق بهادار را مورد بررسی قرار دهد. هدف ارزیابی ریسک حساسیتی با استفاده از الگوی شبکه عصبی مصنوعی و الگوی ترکیبی شبکه عصبی پرسپترون چند لایه با الگوریتم بهینه‌سازی اجتماع ذرات و همچنین مقایسه آنها می‌باشد. بنابراین جهت مرتب‌سازی داده‌ها از نرم افزار EXCEL و برای تجزیه و تحلیل یافته‌های پژوهش و کد نویسی هر یک از الگوریتم‌های مورد استفاده از نرم‌افزار MATLAB استفاده گردیده است. در این راستا جهت آزمون فرضیه‌ها و ارزیابی ریسک حساسیتی، از طریق دو الگو به ارزیابی قدرت هر کدام از الگوها پرداخته شده است.

۵-۱. الگوی اول: استفاده از شبکه عصبی چند لایه پرسپترون (MLP)

شبکه‌های عصبی مدل‌های متفاوتی دارند که متداولترین آنها شبکه چند لایه پرسپترون (MLP) است. شبکه‌های عصبی به رغم تنوع از ساختار مشابهی برخوردار است. یک شبکه عصبی معمولاً از سه لایه ورودی، میانی و خروجی تشکیل شده است. لایه ورودی فقط اطلاعات را دریافت و مشابه متغیر مستقل عمل می‌کند، لذا تعداد نرون‌های لایه ورودی به تعداد متغیرهای مستقل بستگی دارد. لایه خروجی نیز همانند متغیر وابسته عمل کرده و تعداد نرون‌های آن بستگی به تعداد متغیر وابسته دارد؛ اما برخلاف لایه ورودی و خروجی، لایه میانی هیچ مفهومی را نشان نمی‌دهد و صرفاً نتیجه لایه میانی در فرایند محاسبه ارزش خروجی است، اما از اهمیت خاصی در فرایند آموزش برخوردار است (پورحیدری و اعظمی، ۱۳۸۹). در الگوریتم چند لایه پرسپترون، ابتدا وزن‌های اولیه شبکه به طور تصادفی انتخاب شده‌اند. در هر گام، خروجی شبکه محاسبه شده و بر حسب جهت و میزان شیب خطا، وزن‌ها اصلاح می‌گردند، تا در نهایت این خطا مینیمم شود. در الگوریتم مربوطه، تلاش برای دستیابی به وزن‌های بهینه شبکه با حرکت در خلاف جهت شیب نمودار خطا بر حسب وزن‌های شبکه صورت می‌گیرد، با این هدف که در هر تکرار اندازه خطا کمتر از تکرار قبلی شود. این نمودار از طریق مشتق‌گیری زنجیره‌ای از تابع خطا نسبت به تک تک وزن‌های شبکه بدست می‌آید. در الگوریتم پس انتشار خطا اگر ضریب یادگیری کوچک در نظر گرفته شود، به طور حتم به نزدیکترین بهینه نسبی می‌رسد، اما الگوریتم در مینیمم محلی گرفتار می‌شود. در صورتی که ضریب یادگیری بزرگ فرض شود، توانایی عبور از مینیمم‌های محلی را دارد و باعث افزایش نسبی سرعت همگرایی می‌شود، اما معمولاً با یافتن حدود مینیمم کلی حول آن نوسان نموده و در اصل به مقدار بهینه کلی نمی‌رسد. در این پژوهش برای نرخ یادگیری (η) مقدار ۰.۰۱ در نظر گرفته شد. برای اصلاح وزن‌های شبکه، ابتدا با استفاده از مشتق زنجیره‌ای، شیب خطا نسبت به هر وزن را محاسبه نموده و در خلاف جهت آن تغییر اندکی متناسب با مقدار نرخ یادگیری در وزن‌ها ایجاد می‌کنیم. میزان تغییر در هر وزن مطابق رابطه (۱) محاسبه می‌گردد.

$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_i} \quad (1)$$

در رابطه فوق η نرخ یادگیری است که مقدار مثبتی را اختیار می‌کند و متناسب است با میزان تغییرات در هر وزن E خطای کلی شبکه و w_{ij} یک پارامتر (وزن) از شبکه است. اگر t_j و y_j به ترتیب خروجی شبکه، خروجی مطلوب برای نرون خروجی j -ام باشد، رابطه (۲) از روابط ذیل بدست می‌آید (پراساد^۱ و همکاران، ۲۰۱۸).

$$\frac{\partial E}{\partial w_i} = \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial w_i} \quad (2)$$

$$\frac{\partial E}{\partial y_j} = (y_j - t_j) \quad (3)$$

$$\frac{\partial y_j}{\partial w_i} = (y_j (1 - y_j)) \cdot w_i \quad (4)$$

در طراحی یک الگوی شبکه عصبی، در واقع باید تعداد لایه‌های میانی شبکه، تعداد نرون‌های هر لایه، الگوریتم‌های یادگیری، تابع تبدیل، تابع عملکرد، تعداد تکرارها، نرمال کردن داده‌ها، اندازه مجموعه آموزشی و یادگیری مشخص گردد. در تعیین این موارد روشهای سیستماتیک وجود ندارد، بنابراین بهترین طراحی شبکه با استفاده از تجربه و آزمایش و خطا به دست می‌آید (مکیان و همکاران، ۱۳۸۸).

در ابتدا داده‌ها وارد محیط نرم افزاری Excel شده و پس از محاسبات مورد نیاز و تعیین بیشترین و کمترین داده‌ها نرمال می‌شوند. پس از نرمال شدن، داده‌ها به دو قسمت تقسیم می‌شوند: مجموعه آموزشی یا یادگیری شبکه شامل ۲۷۰ مشاهده (شرکت - سال) از شرکتهای نمونه، مجموعه تست شامل ۹۰ شرکت از شرکتهای نمونه در سال ۱۳۹۶ تا ۱۳۹۸ هستند. در گام بعدی اقدام به ارزیابی با استفاده از شبکه‌های عصبی مصنوعی شده است. برای انجام این مهم از جعبه ابزار شبکه‌های عصبی مصنوعی در نرم افزار MATLAB استفاده شده است.

۵-۲. الگوی دوم: استفاده از روش ترکیبی شبکه عصبی و الگوریتم بهینه سازی اجتماع ذرات (MLP-PSO)

این الگوریتم در متون فارسی با عناوین دیگری از قبیل توده ذرات، انبوه ذرات و ازدحام ذرات نیز شناخته می‌شود. این الگوریتم برای اولین بار توسط کندی و ابرهارت^۱ (۱۹۹۵) به کار برده شد. این الگوریتم الهام گرفته از پرواز همزمان پرندگان، شنای دسته جمعی ماهی‌ها و زندگی اجتماعی آنها است. پرندگان با استفاده از تجربه یکدیگر و با تجدید موقعیت به راه حل بهینه که همان منبع غذایی است، دست می‌یابند (نیپانیکار^۲ و همکاران، ۲۰۱۸).


1. Kennedy and Eberhart

2. Nipanikar

۵-۲-۱. بیان یک راه‌حل ممکن برای مسئله

در الگوریتم بهینه‌سازی اجتماع ذرات، یک راه‌حل ممکن برای مسئله توسط موقعیت یک ذره در فضای N بعدی بیان می‌شود، که N تعداد متغیرهای مسئله است. در روش پیشنهادی مبتنی بر شبکه عصبی و الگوریتم بهینه‌سازی اجتماع ذرات (MLP-PSO)، به طور هم‌زمان قصد داریم ویژگی‌های مهم در تشخیص ریسک و نیز وزن‌های شبکه عصبی را بطور هم‌زمان بهینه کنیم. بنابراین در روش پیشنهادی MLP-PSO، یک راه‌حل ممکن برای مسئله را می‌توان مطابق شکل (۳)، به صورت یک بردار به طول $N+F$ بیان کرد، که N تعداد کل وزن‌های شبکه عصبی و F تعداد کل ویژگی‌های موجود در داده است. مقدار هر وزن w_i می‌تواند یک عدد پیوسته در بازه $[-1, 1]$ باشد، درحالی که مقدار هر f_i یک عدد باینری $\{0, 1\}$ می‌باشد.

شکل شماره ۳: یک راه‌حل ممکن برای مسئله (مطیع قادر و همکاران، ۱۳۸۹)



۵-۲-۲. تولید جمعیت اولیه تصادفی

الگوریتم بهینه‌سازی اجتماع ذرات با مقداردهی یک گروه تصادفی از ذرات در فضای جستجو L بعدی مدل‌سازی می‌شود که هر ذره بیانگر یک راه‌حل می‌باشد و L تعداد کل متغیرهای بهینه‌سازی است که در این پژوهش برابر با $L=N+F$ است. این جمعیت از ذرات دارای دو توانایی اصلی هستند، آن‌ها حافظه‌ای برای ذخیره‌سازی بهترین مکان خود دارند و دیگر این که در مورد بهترین موقعیت ذرات در کل فضای جستجو آگاهی دارند و مکان‌های خوب را به یکدیگر از طریق ارتباط انتقال می‌دهند و موقعیت و سرعتشان را با مکان‌های خوب تنظیم می‌کنند. هر ذره در الگوریتم بهینه‌سازی اجتماع ذرات دارای یک بردار موقعیت $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{iL})$ و سرعت $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{iL})$ می‌باشد که سرعت هر ذره با حرکت آن ذره متناسب است و هدایت حرکت ذره را بر عهده دارد (پراساد و همکاران، ۲۰۱۸). در ابتدا، جمعیت اولیه الگوریتم بهینه‌سازی اجتماع ذرات به صورت تصادفی ایجاد می‌گردد. برای این کار، موقعیت هر ذره در فضای پنج بعدی مطابق شکل (۳) به صورت تصادفی تعیین می‌شود.

۵-۲-۳. تابع هدف مسئله

در هر تکرار از الگوریتم بهینه‌سازی اجتماع ذرات، بعد از بروز رسانی جمعیت، بایستی خطای

هر ذره با استفاده از تابع هدف ارزیابی شود. تابع هدف الگوریتم بهینه سازی اجتماع ذرات به صورت مینیمم کردن میانگین مربعات خطا (MSE) در نظر گرفته شده است.

۴-۲-۵. بروز رسانی جمعیت در الگوریتم بهینه سازی اجتماع ذرات

معادلات حاکم بر هر ذره در الگوریتم بهینه سازی اجتماع ذرات به صورت زیر می باشد:

$$v_{id}(t+1) = w \cdot v_{id}(t) + c_1 \cdot r_1 \cdot (p_{best_{id}} - x_{id}(t)) + c_2 \cdot r_2 \cdot (g_{best_d} - x_{id}(t)) \quad (5)$$

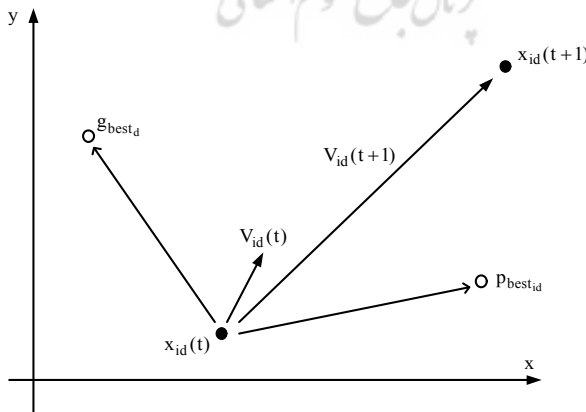
$$v_{mind} \leq v_{id} \leq v_{maxd}, \quad i = 1, \dots, n \quad (6)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1), \quad (7)$$

$$x_{mind} \leq x_{id} < x_{maxd}, \quad i = 1, \dots, n \quad (8)$$

به طور کلی در الگوریتم بهینه سازی اجتماع ذرات، حرکت هر ذره در فضای جستجو در دو جهت صورت می گیرد: یکی حرکت به سمت بهترین موقعیتی که خود ذره تاکنون در آن قرار گرفته است P_{best} و دیگری حرکت به سمت بهترین موقعیتی که در همسایگی ذره از ابتدا تا کنون وجود داشته است g_{best} . همان طور که از شکل (۴) مشخص است هر ذره به سمت یک میانگین وزنی از این دو جهت حرکت می کند. در این دیاگرام برداری، برای حالتی که ذرات دو بعدی باشند، اندیس ۱ نشان دهنده ۱-امین ذره، و اندیس d نشان دهنده d-امین بعد هر ذره است (کندی و ابرهارت، ۱۹۹۵).

شکل شماره ۴: دیاگرام برداری معادلات (۵) تا (۸) در حالت دو بعدی



در اولین تکرار الگوریتم، مختصات تصادفی هر ذره به عنوان P_{best} آن ذره نیز محسوب می‌شود. در هر تکرار الگوریتم P_{best} به روزرسانی می‌شود بدین صورت که ذره جاری با ذره تکرار قبل خود در ماتریس P_{best} مقایسه می‌شود. اگر میزان تابع هر ذره از میزان تابع در P_{best} مربوط به آن ذره کمتر باشد، مختصات ذره جدید در P_{best} قرار می‌گیرد و ذره قبلی موجود در P_{best} فراموش می‌گردد، در غیر این صورت P_{best} همان P_{best} قبلی باقی می‌ماند. همچنین بهترین ذره کلی از جمعیت P_{best} در همه تکرارها نیز به عنوان g_{best} ذخیره می‌گردد. در هر تکرار الگوریتم، کیفیت تمام ذرات با تابع هزینه متناسب با مسئله ارزیابی شده و مکان هر ذره با توجه به روابط (۵) تا (۸) به روزرسانی می‌شود تا در نهایت راه‌حل بهینه یافت شود. مراحل بالا تا رسیدن به شرط توقف ادامه می‌یابد (کندی و ابرهات، ۱۹۹۵).

محاسبه سرعت هر ذره توسط دو مقدار بهترین، بهترین موقعیت فردی و بهترین موقعیت اجتماعی هر ذره انجام می‌شود، به طوری که حرکت ذرات در جهت کاهش فاصله موقعیت جاری خود با بهترین تجربه شخصی و تج. به اجتماعی صورت می‌گیرد. بنابراین سرعت هر ذره مطابق با رابطه (۵) بروزرسانی می‌گردد. V_{id} سرعت هر ذره در تکرار قبل می‌باشد که در اولین تکرار مقدار آن توسط کاربر تعیین می‌گردد.

مطابق رابطه (۵)، شتاب هر ذره به سمت P_{best} و g_{best} از طریق دو ضریب وزنی C_1 و C_2 انجام می‌شود. C_1 و C_2 ضرایب شتاب نامیده می‌شوند که مقادیری ثابت و مثبت اختیار می‌کنند. C_1 ضریبی است که مشخص می‌کند ذره تا چه اندازه تحت تاثیر بهترین تجربه فردی یا بهترین وضعیت حافظه خود (P_{best}) قرار می‌گیرد و C_2 بیان‌کننده تاثیر است که هر ذره از بهترین تجربه گروهی یا بهترین ذره از ابتدا تاکنون (g_{best}) دریافت می‌کند. این ضرایب معمولاً در بازه صفر تا ۲ انتخاب می‌شوند. همچنین I_1 و I_2 نیز اعدادی تصادفی در بازه (۰ و ۱) می‌باشند که باعث تنوع حرکت ذرات بین P_{best} و g_{best} می‌شوند (کندی و ابرهات، ۱۹۹۵).

در هر تکرار، بعد از بروز رسانی سرعت ذرات، اگر سرعت ذره از V_{max} تجاوز کند، سرعت ذره را به V_{max} محدود می‌کنیم. مقدار V_{max} برای هر مسئله به طور مجزا و با توجه به ابعاد مسئله تعریف می‌شود. اگر V_{max} خیلی بزرگ باشد، ذرات، فضای جستجو را با سرعت بیشتری مورد کاوش قرار می‌دهند که ممکن است از برخی از جواب‌های مناسب به سرعت بگذرد و اگر خیلی کوچک باشد باعث می‌شود، ذرات در دام مینیمم محلی گرفتار شده و نتوانند تمام فضای مسئله را مورد جستجو قرار دهند و تکرار بیشتری برای رسیدن به بهینه لازم باشد. بنابراین لازم است V_{max} به گونه‌ای انتخاب شود که بین حرکت تند و کند ذرات در فضای جستجو و جستجوی ثابت توازن ایجاد شود.

W_i پارامتر اینرسی وزنی است که مشخص می‌کند سرعت قبلی هر ذره چگونه روی سرعت تکرار جاری تاثیر می‌گذارد. تنظیم پارامتر اینرسی وزنی با استفاده از رابطه (۹) محاسبه می‌گردد. در این رابطه اگر W_i برابر با صفر باشد سرعت ذره فقط با توجه به موقعیت P_{best} و g_{best} تعیین

می‌گردد. W_i مطابق رابطه ذیل تنظیم می‌گردد که در آن W_i به صورت خطی در هر تکرار کاهش می‌یابد.

$$W_i = W_{max} + (iter / iter_{max}) \cdot (W_{max} - W_{min}) \quad (9)$$

که در رابطه بالا، $iter_{max}$ ماکزیمم تعداد تکرارها و $iter$ شماره تکرار فعلی می‌باشد و W_{min} و W_{max} در اکثر مراجع به ترتیب ۰٫۹ و ۰٫۱ انتخاب می‌گردند (پراساد و همکاران، ۲۰۱۸).

در هر تکرار بعد از بروز رسانی سرعت ذرات، در نهایت موقعیت هر ذره از رابطه (۱۱) بروز رسانی می‌شود که در آن $v_{id}(t+1)$ بیانگر سرعت جاری و $x_{id}(t)$ معرف موقعیت قبلی هر ذره است.

پارامترهای الگوریتم بهینه سازی اجتماع ذرات مطابق جدول (۵) تعیین گردید.

جدول ۵: پارامترهای الگوریتم بهینه سازی اجتماع ذرات (پراساد و همکاران، ۲۰۱۸)

مقدار	پارامتر
۵۰	جمعیت (تعداد ذرات)
۱۰۰	تعداد تکرارهای الگوریتم
۲	C_1
۱٫۵	C_2
۰٫۹	W_{max}
۰٫۱	W_{min}
۰٫۱	V_{max}

لذا در این پژوهش، برای بررسی میزان خطای پیش بینی الگوهای مورد استفاده از شاخص‌های آماری و معادلات رگرسیونی که بیش از همه متداول هستند استفاده می‌شود. شاخص‌های مورد استفاده در این پژوهش عبارتند از: میانگین درصد خطا (MPE)^۱، میانگین قدرمطلق خطا (MAE)^۲ و مجذور میانگین مربعات خطا (RMSE)^۳ و ضریب همبستگی (R) (متها^۴ و همکاران، ۲۰۱۴).

$$MPE = \frac{1}{N} \sum_{i=1}^N \frac{|Output_i - Target_i|}{Target_i} \times 100 \quad (10)$$

1. Mean Percentage Error
2. Mean Absolute Error
3. Root Mean Square Error
4. Mathaba

$$MAE = \frac{1}{N} \sum_{i=1}^N |\text{Output}_i - \text{Target}_i| \quad (11)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{Output}_i - \text{Taret}_i)^2} \quad (12)$$

$$R = \frac{\frac{1}{N} \sum_{i=1}^N |\text{Output}_i - \overline{\text{Output}}| \times |\text{Target}_i - \overline{\text{Target}}|}{\sqrt{\frac{1}{N} \sum_{i=1}^N (\text{Output}_i - \overline{\text{Output}})^2} \times \sqrt{\frac{1}{N} \sum_{i=1}^N (\text{Target}_i - \overline{\text{Target}})^2}} \quad (13)$$

همان طور که فرمول‌های مربوط به هر معیار نشان می‌دهد هر کدام از این معیارها مبین یک مطلب می‌باشند. معیار اول نشان دهنده متوسط درصد خطای بین نتایج بدست آمده از مقایسه بین داده‌های واقعی و پیش‌بینی شده، معیار دوم نشان دهنده متوسط قدر مطلق خطای بین نتایج بدست آمده از مقایسه بین داده‌های واقعی و پیش‌بینی شده، معیار سوم نشان دهنده متوسط خطای بین نتایج بدست آمده از مقایسه بین داده‌های واقعی و پیش‌بینی شده و معیار چهارم ضریب همبستگی مابین مقادیر پیش‌بینی شده از شبکه عصبی و داده‌های خروجی حاصل از الگوسازی عددی به عنوان معیار مناسب جهت ارزیابی توانایی شبکه مد نظر می‌باشد (آذر و مومنی، ۱۳۹۵).

۶. یافته‌های پژوهش

در این پژوهش به بررسی ریسک حساسیتی با استفاده از شبکه‌های عصبی در ۹۰ شرکت از شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران پرداخته که داده‌های اندازه‌گیری شده بصورت تصادفی توسط الگوریتم‌های شبکه عصبی آموزش داده می‌شوند (داده‌های آموزشی) که نتایج آن در نمودارها و جداول زیر نمایش داده شده است. سپس داده‌های اندازه‌گیری شده باقیمانده به منظور تست کردن مدلها بکار برده شده است که از این راه می‌توان تخمین زد که دقت مدل‌های پیش‌بینی شده توسط شبکه‌های عصبی در عمل به چه اندازه می‌باشد. از این رو به منظور بررسی عملکرد مدل‌ها، بطور متداول از برخی از معیارهای ارزیابی عملکرد برای نشان دادن چگونگی یادگیری ارتباط داده‌ها در شبکه عصبی استفاده شده است. برای مسائل ارزیابی، این معیارها بطور عمده مربوط به خطای بین خروجی پیش‌بینی شده و خروجی مطلوب

واقعی است در پژوهش حاضر از چهار معیار رایج ارزیابی عملکرد استفاده شده است: میانگین درصد خطا (MPE)، میانگین قدر مطلق خطا (MAE)، مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی (R). شبکه‌ای که دارای کمترین مقادیر سه خطای مذکور و نزدیک ترین مقدار (R) را به یک داشته باشد به عنوان بهترین شبکه تلقی می‌گردد.

۶-۱. نتایج الگوی شبکه‌های عصبی پرسپترون چند لایه (MLP)

یکی از ویژگی‌های شبکه‌های عصبی عدم وجود قانون تأیید شده برای معماری شبکه آنها است؛ کارایی یک الگو بر پایه شبکه عصبی چند لایه پرسپترون به ساختار شبکه و تعیین پارامترهای آن بستگی دارد معیار مناسبی برای تعیین تعداد لایه و تعداد نرون در لایه میانی، نوع تابع فعال‌سازی برای لایه میانی وجود نداشته و تنها راه حل استفاده از روش آزمون و خطا برای انتخاب بهترین شبکه است (گازلیبی^۱، ۲۰۰۶).

هدف از آموزش شبکه عصبی، تعیین مقادیر وزن‌ها برای دستیابی به بهترین شبکه برای الگوسازی تابع هدف است. از آنجا که مقدار خروجی متناظر با بردار ورودی تعیین شده در شبکه وارد می‌شوند، بهترین نوع یادگیری از نوع یادگیری با ناظر است. در میان قوانین یادگیری با ناظر، الگوریتم پس انتشار خطا از طریق لایه‌های شبکه و در خلاف مسیر ارتباط وزن نرون‌ها، مقدار خطا حاصل از محاسبه در مسیر رفت را در مسیر برگشت توزیع کرده و در نتیجه کاربرد شبکه عصبی مصنوعی در محاسبات را بطور چشم‌گیری افزایش می‌دهد. در این پژوهش نیز از همین قانون آموزش استفاده شده است. بر اساس پارامترهای جدول (۶) و با بررسی و آزمون شبکه عصبی با پنج ساختار مختلف به شرح جدول (۷) مورد بررسی قرار گرفت.

جدول شماره ۶: پارامترهای اصلی شبکه عصبی (مطیع قادر و همکاران، ۱۳۸۹)

نوع ساختار	تابع فعال‌سازی	نرخ یادگیری	تعداد نرون لایه پنهان اول	تعداد نرون لایه پنهان دوم
تابع پایه شعاعی پرسپترون چند لایه	انتقال تانژانت هیپربولیک	۰,۰۱	[۲۰-۱]	[۱۵-۱]

جدول شماره ۷: ساختارهای مختلف پیشنهادی شبکه عصبی (مطیع قادر و همکاران، ۱۳۸۹)

الگو	تعداد لایه‌های مخفی	تعداد نرون‌های لایه اول	تعداد نرون‌های لایه دوم	تعداد لایه خروجی
MLP- I	۲	۵	۵	۱
MLP- II	۲	۱۰	۵	۱
MLP- III	۲	۱۰	۱۰	۱
MLP- IV	۲	۲۰	۱۰	۱
MLP-V	۲	۲۰	۱۵	۱

معمولاً تعداد نرون‌ها در لایه‌های پنهان با سعی و خطا مشخص می‌شود و از قاعده مشخصی پیروی نمی‌کند. اگر تعداد نرون‌ها کم باشد شبکه قادر به یادگیری نخواهد بود و چنانچه تعداد نرون‌ها زیاد باشد، پدیده بیش یادگیری روی می‌دهد و شبکه به جای اینکه رابطه بین ورودی و خروجی‌ها را یاد بگیرد آن را حفظ می‌کند و خطای شبکه در آزمون بالا می‌رود (مطیع قادر و همکاران، ۱۳۸۹). همچنین در لایه میانی ما نرون‌های مخفی را داریم. در اکثر مسائل پیش‌بینی تعداد ۱۰ تا ۲۰ نرون مناسب خواهند بود (یانگ^۱ و همکاران، ۲۰۱۹).

بر اساس جدول (۸) در نهایت یک شبکه عصبی چند لایه پرسپترون پس از حداقل نمودن خطای موجود در الگوی آموزش و ارزیابی با تنظیم وزن‌ها به عنوان بهترین شبکه‌ها تعیین گردید. بهترین مقدار ضریب همبستگی، میانگین مجذور خطا و مجذور میانگین مربعات خطا در الگوهای پیشنهادی مطابق جدول (۸) به ترتیب ۰,۹۵۲، ۰,۰۵۴، ۰,۲۳۴ و در فاز آموزش و در فاز ارزیابی ۰,۹۳۹، ۰,۰۵۲، ۰,۲۲۸ و همگی در الگو MLP- II هستند. نامناسب‌ترین مقادیر در فاز آموزش ۰,۰۹۸، ۰,۰۹۴، ۰,۳۱۴ و ۰,۹۱۲، ۰,۱۱۵، ۰,۳۴ و همگی به ترتیب در الگوهای MLP- I و MLP-V می‌باشد. در نهایت یک شبکه (MLP- II) با دو لایه پنهان و ۱۰ نرون در لایه پنهان اول و ۵ نرون در لایه پنهان دوم، و توابع انتقال سیگموئید به عنوان بهترین شبکه تعیین می‌شود.

جدول شماره ۸: نتایج ارزیابی ساختارهای پیشنهادی (منبع: خروجی متلب)

الگو	ضریب همبستگی		میانگین مجذور خطا		مجذور میانگین مربعات خطا	
	آموزش	ارزیابی	آموزش	ارزیابی	آموزش	ارزیابی
MLP- I	۰,۹۰۴	۰,۸۵۶	۰,۰۹۸	۰,۱۰۷	۰,۳۱۴	۰,۳۲۷
MLP- II	۰,۹۵۲	۰,۹۳۹	۰,۰۵۴	۰,۰۵۲	۰,۲۳۴	۰,۲۲۸
MLP- III	۰,۹۳۸	۰,۹۰۱	۰,۰۷۲	۰,۰۹۲	۰,۲۷	۰,۳۰۴
MLP- IV	۰,۹۴۵	۰,۹۲۱	۰,۰۵۸	۰,۰۷۶	۰,۲۴۲	۰,۲۷۷
MLP-V	۰,۹۱۲	۰,۸۷۸	۰,۱۱۵	۰,۱۱۳	۰,۳۴	۰,۳۳۷

با بررسی فاز ارزیابی کلیه مقادیر به دست آمده در الگوهای پیشنهادی نشان می‌دهند که تمامی آنها به خوبی آموزش دیده و توانایی پیش‌بینی ریسک حساسیتی در محدوده مورد بررسی در این پژوهش را دارند. پس از تعیین ساختار شبکه و مجموعه ورودی‌های آن، شبکه برای آموزش آماده می‌شود. همان گونه که پیشتر اشاره شد در این مطالعه به منظور آموزش شبکه‌های عصبی با در نظر گرفتن محدودیت مشاهدات علاوه بر الگوریتم رایج (MLP) از الگوریتم تکاملی (MLP-PSO) نیز استفاده شده است.

یکی از مواردی که بر عملکرد الگوریتم‌ها تاثیرگذار است تعیین بهینه پارامترهای آن الگوریتم است. این مورد آنقدر اهمیت دارد که انتخاب نادرست پارامترها ممکن است کارایی الگوریتم را تا اندازه زیادی کاهش دهد. در فرایند آموزش شبکه از مهمترین پارامترها، پارامتر تعداد تکرار است. هر چقدر تعداد تکرارها بیشتر باشد زمان اختصاص داده شده به الگوریتم برای همگرایی و در نتیجه شناس همگرایی الگوریتم افزایش پیدا می‌کند. البته باید توجه داشت اگر تعداد تکرارها از یک حدی بیشتر باشد دیگر در همگرایی الگوریتم تاثیری نداشته و در واقع بعد از آن تکرار روند همگرایی ثابت خواهد بود. نمودارهای شماره (۱) و (۶) هر یک فرآیند یادگیری شبکه بر اساس ۱۰۰ تکرار را به ترتیب برای شبکه‌های MLP و MLP-PSO نشان می‌دهد. همانگونه که نتایج نشان می‌دهد روند یادگیری شبکه بر اساس الگوریتم تکاملی بسیار بهتر از الگوریتم MLP بوده و در انتهای فرآیند یادگیری خطای کمتری داشته‌اند.

به منظور بررسی دقت پیش‌بینی شبکه، از روشهای ارزیابی عملکرد فوق استفاده کردیم که نتایج مقادیر خطا و همبستگی برای داده‌های آموزش و تست در جدول (۹) ارائه شده است. با توجه به نتایج حاصله الگوی شبکه عصبی پرسپترون چند لایه با معیارهای عملکرد خطا و ضریب همبستگی در فاز آموزش و در فاز ارزیابی توانایی ارزیابی ریسک حساسیتی را با درصد خطای پایین و همبستگی بالا را دارد.

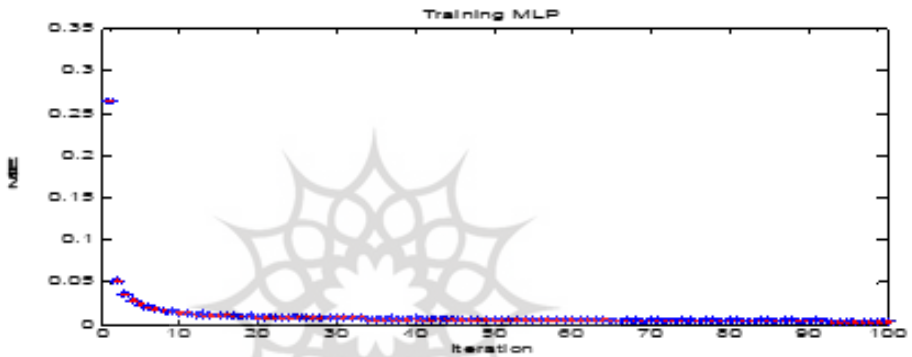
جدول شماره ۹: خلاصه مقادیر شاخص‌های خطای شبکه عصبی پرسپترون چند لایه (منبع: خروجی متلب)

معیار شاخص	داده‌های آموزش	داده‌های تست
میانگین قدر مطلق خطا	۰,۰۲۳	۰,۰۱۹
مجدور میانگین مربعات خطا	۰,۰۳۱	۰,۰۲۶
میانگین درصد خطا	۶,۶۷۸	۶,۳۶۶
ضریب همبستگی	۰,۹۶۸	۰,۸۷۶
تفاوت بین ضریب همبستگی داده‌ها	۰,۰۹۲	

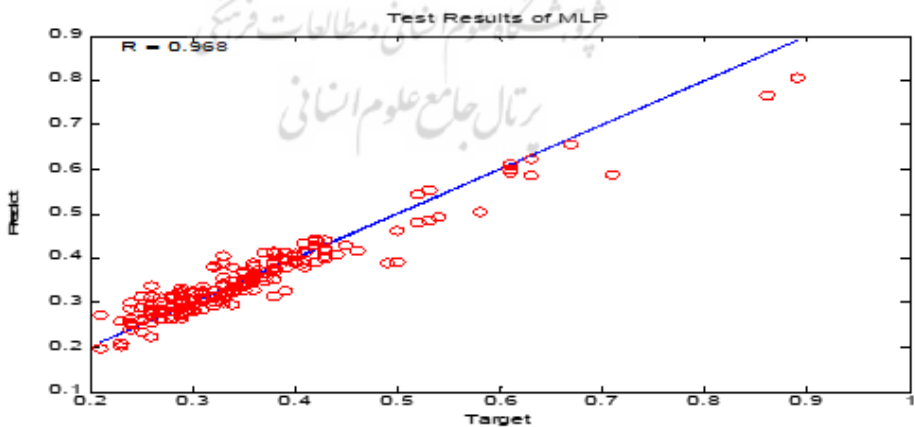
همچنین پایین بودن تفاوت بین ضریب همبستگی در دو دسته آموزش و تست، نشان دهنده کارآمد بودن الگو شبکه عصبی (MLP) در راستای پیش‌بینی ریسک حساسیتی است.

نمایش هندسی پیش بینی تغییرات ریسک حساسیتی را برای داده‌های آموزش و تست نشان داده است. نمودار (۱) نمودار آموزش شبکه عصبی MLP بر حسب تکرار می‌باشد که نشان دهنده این است که به هر بار تکرار خطای کاهش می‌یابد. نمودار (۲) و (۳) نمودار همبستگی در شبکه عصبی MLP را نشان می‌دهد. نمودار (۴) و (۵) مقایسه خروجی‌های واقعی و تخمینی توسط شبکه عصبی MLP را بر اساس داده‌های آموزش و تست نشان می‌دهد.

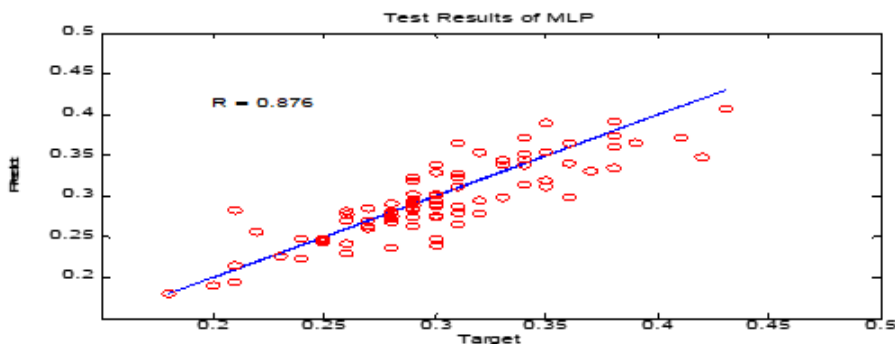
نمودار شماره ۱: آموزش شبکه عصبی MLP بر حسب تکرار
(آموزش با استفاده از الگوریتم کلاسیک پس انتشار خطا)



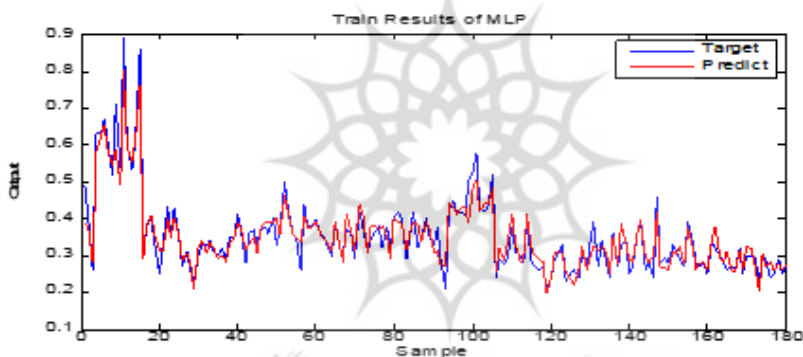
نمودار شماره ۲: همبستگی در شبکه عصبی MLP (به ازای نمونه‌های آموزش)



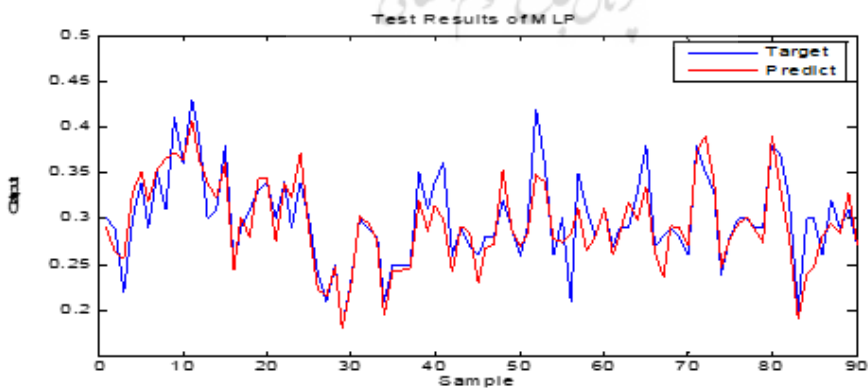
نمودار شماره ۳: همبستگی در شبکه عصبی MLP (به ازای نمونه‌های تست)



نمودار شماره ۴: مقایسه خروجی‌های واقعی و تخمینی توسط شبکه عصبی MLP (به ازای نمونه‌های آموزش)



نمودار شماره ۵: مقایسه خروجی‌های واقعی و تخمینی توسط شبکه عصبی MLP (به ازای نمونه‌های تست)



۶-۲. نتایج الگوی ترکیبی شبکه عصبی و الگوریتم تجمع ذرات (MLP-PSO)

در اجرای الگوی دوم از الگوریتم تجمع ذرات به عنوان یک روش بهینه‌سازی که دستیابی به مقادیر مطلوب پارامترهای شبکه عصبی را میسر می‌سازد استفاده شده است. بهینه‌سازی شبکه عصبی با استفاده از الگوریتم تجمع ذرات، مستلزم تعیین پارامترهای اصلی الگوریتم تجمع ذرات است. پارامترهای اصلی الگوریتم تجمع ذرات به منظور پیش‌بینی در جدول (۱۰) نمایش داده شده است.

جدول شماره ۱۰: پارامترهای اصلی الگوریتم تجمع ذرات (منبع: خروجی متلب)

متغیر پیش‌بینی شده	وزن اینرسی	تعداد ذرات	فاکتور یادگیری
ریسک حساسیتی	{-۱، ۰}	۵۰	۲

مقادیر محاسبه شده شاخص‌های خطا و ضریب همبستگی در الگوی ترکیبی شبکه عصبی الگوریتم تجمع ذرات در جدول (۱۱) نشان داده شده است. با توجه به نتایج حاصله الگوی ترکیبی شبکه عصبی الگوریتم اجتماع ذرات (MLP-PSO) نسبت به الگوی شبکه عصبی (MLP) باعث کاهش میزان خطاها (میانگین قدر مطلق خطا، مجذور میانگین مربعات خطا، میانگین درصد خطا) و افزایش ضریب همبستگی در فاز آموزش به ترتیب به میزان (۰,۰۱۳، ۰,۰۱۸، ۳,۶۰۶، ۰,۹۸۸) و در فاز تست به میزان (۰,۰۱۷، ۰,۰۲۳، ۵,۷۴۳، ۰,۹۲۰) گردید.

جدول شماره ۱۱: مقادیر شاخص‌های شبکه عصبی مبتنی بر الگوریتم تجمع ذرات (منبع: خروجی متلب)

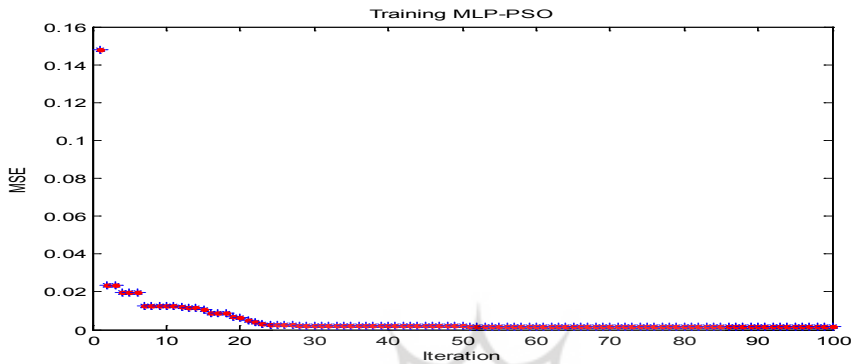
معیار شاخص	داده‌های آموزش	داده‌های تست
میانگین قدر مطلق خطا	۰,۰۱۳	۰,۰۱۷
مجذور میانگین مربعات خطا	۰,۰۱۸	۰,۰۲۳
میانگین درصد خطا	۳,۶۰۶	۵,۷۴۳
ضریب همبستگی	۰,۹۸۸	۰,۹۲۰
تفاوت بین ضریب همبستگی داده‌ها	۰,۰۶۸	

همچنین پایین بودن تفاوت بین ضریب همبستگی در دو دسته آموزش و تست، نشان دهنده کارآمد بودن الگوی ترکیبی شبکه عصبی الگوریتم اجتماع ذرات (MLP-PSO) در راستای پیش‌بینی ریسک حساسیتی است.

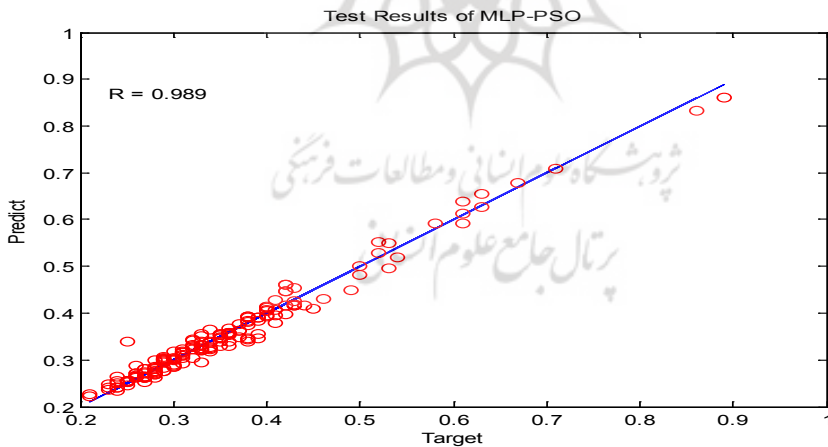
نمودار (۶) نمودار آموزش شبکه عصبی MLP-PSO بر حسب تکرار می‌باشد که نشان دهنده این است که به هر بار تکرار خطای کاهش می‌یابد. نمودار (۷) و (۸) نمودار همبستگی در شبکه عصبی MLP-PSO را نشان می‌دهد. نمودار (۹) و (۱۰) مقایسه خروجی‌های واقعی و

تخمینی توسط شبکه عصبی MLP-PSO را بر اساس داده‌های آموزش و تست نشان می‌دهد.


نمودار شماره ۶: آموزش شبکه عصبی MLP-PSO بر حسب تکرار
(آموزش با استفاده از الگوریتم بهینه‌سازی اجتماع ذرات)



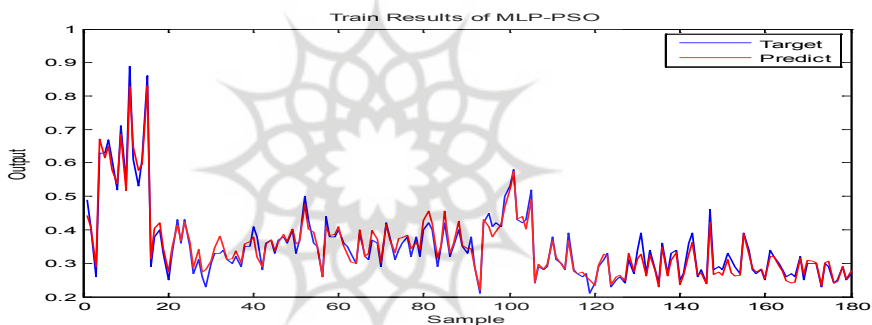
نمودار شماره ۷: همبستگی در روش MLP-PSO (به ازای نمونه‌های آموزش)




نمودار شماره ۸: همبستگی در روش MLP-PSO (به ازای نمونه‌های تست)



نمودار شماره ۹: مقایسه خروجی‌های واقعی و تخمینی توسط روش MLP-PSO (به ازای نمونه‌های آموزش)



نمودار شماره ۱۰: مقایسه خروجی‌های واقعی و تخمینی توسط روش MLP-PSO (به ازای نمونه‌های تست)



همچنین مقایسه نتایج جدول (۱۲) ضمن تائید عملکرد بهتر MLP-PSO و مقایسه با MLP نشان‌دهنده قدرت پیش بینی بالاتر شبکه‌های عصبی مبتنی بر الگوریتم‌های تکاملی در مقایسه با الگوریتم‌های پس انتشار خطا می‌باشد.

جدول شماره ۱۲: خلاصه مقادیر شاخص‌های خطای انواع الگوهای پژوهش (منبع: خروجی متلب)

الگو	داده‌های آموزش				داده‌های تست			
	R	MPE	RMSE	MAE	R	MPE	RMSE	MAE
MLP	۰,۰۲۳	۶,۶۷۸	۰,۰۳۱	۰,۰۶۸	۰,۰۲۶	۶,۳۶۶	۰,۰۲۶	۰,۰۱۹
PSO	۰,۰۱۳	۳,۶۰۶	۰,۰۱۸	۰,۰۹۸۸	۰,۰۲۳	۵,۷۴۳	۰,۰۲۳	۰,۰۱۷

۷. بحث و نتیجه‌گیری

حسابرسان برای ارائه یک اظهار نظر معقول باید تمامی مراحل حساسیتی را با توجه به ریسک‌های موجود برنامه‌ریزی نمایند. تعیین میزان آزمون‌های محتوا در جهت کشف تقلب و انحرافات از قوانین و مقررات به میزان ریسک کنترل‌های داخلی واحد مورد رسیدگی بستگی دارد. چنانچه حسابرسان بتوانند ارزیابی مناسبی از ریسک حساسیتی داشته باشند در نهایت می‌توانند قضاوت صحیح‌تری داشته باشند. این موضوع در شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران که دارای پیچیدگی‌های بیشتری هستند از اهمیت بیشتری برخوردار است. هدف اصلی این پژوهش پیش‌بینی ریسک حساسیتی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از ابزارهای جدید در حوزه علم داده کاوی مبتنی بر شبکه‌های عصبی است. در جهت دستیابی به هدف پژوهش به سوالات زیر پاسخ داده شد:

۱. آیا الگوی شبکه عصبی (پرسپترون چند لایه) از توانایی لازم برای ارزیابی ریسک حساسیتی برخوردار است؟
۲. آیا الگوی شبکه عصبی فرا ابتکاری (ترکیب شبکه عصبی با الگوریتم بهینه‌سازی اجتماع ذرات) از توانایی لازم برای ارزیابی ریسک حساسیتی برخوردار است؟
۳. آیا دقت الگوی شبکه عصبی فرا ابتکاری (ترکیب شبکه عصبی با الگوریتم بهینه‌سازی اجتماع ذرات) جهت ارزیابی ریسک حساسیتی از الگوی شبکه عصبی (پرسپترون چند لایه) بیشتر است؟

نتایج حاصل از خروجی نرم افزار متلب مرتبط با ۹۰ شرکت بورسی نشان داد که الگوی شبکه عصبی (پرسپترون چند لایه) و همچنین الگوی شبکه عصبی فرا ابتکاری (ترکیب شبکه عصبی با الگوریتم بهینه‌سازی اجتماع ذرات) از توانایی لازم برای ارزیابی ریسک حساسیتی برخوردارند. علت برتری الگوریتم‌های ترکیبی، جستجوی نقاط بهینه سراسری و عدم فرار گیری در بهینه محلی توسط این الگوریتم است. از طرفی چون منبع غنی از داده‌ها وجود دارد، در آموزش شبکه، عملکرد بهینه الگوریتم ترکیبی بیشتر می‌شود. در مقابل مراحل این الگوریتم به مراتب زیادتر و پیچیده‌تر است. باید اذعان داشت که با توجه به بهینه شدن وزن‌های اولیه تصادفی به وسیله الگوریتم‌های فرا ابتکاری، به نظر می‌رسد کارایی بالاتر مدل‌های الگوریتم فرا ابتکاری در پیش‌بینی ریسک حساسیتی به همین علت باشد.

بطور خلاصه ترکیب شبکه عصبی، الگوریتم تجمع ذرات به منظور شناسایی متغیرهای

مؤثر در پیش‌بینی، قدرت پیش‌بینی را به طور محسوسی افزایش می‌دهد؛ زیرا تمامی معیارهای ارزیابی ترکیب شبکه عصبی الگوریتم تجمع ذرات بهتر است و می‌تواند به نسبت جواب بهتری در حل مسائل بهینه‌سازی بدست آورد. در واقع ترکیب الگوریتم تجمع ذرات قادر است تا متغیرهای ورودی مؤثر را انتخاب کرده و عدم کارایی متغیرهای نامؤثر را به حداقل برساند. با توجه به اینکه تفاوت الگو، در روش انتخاب متغیرهای ورودی شبکه است، هر گونه قدرت توضیحی بیشتر به استفاده یا عدم استفاده الگوریتم تجمع ذرات مربوط می‌شود. با توجه به ماهیت الگوریتم تجمع ذرات نیز چنین نتایجی نیز انتظار می‌رفت. پژوهش حاضر از لحاظ تایید قدرت پیش‌بینی شبکه‌های عصبی با پژوهش‌های ژانگ (۲۰۲۱)، هوپینگ (۲۰۲۱)، وی روبکا (۲۰۲۰)، فونگ تاو و همکاران (۲۰۱۹)، آیلا (۲۰۱۷)، همتی و همکاران (۱۳۹۹) و مسیحی و همکاران (۱۳۹۸) همخوانی داشت.

به موسسات حساسیتی پیشنهاد می‌شود که با بررسی منفعت - هزینه استفاده از شبکه‌های عصبی پس از آموزش کارکنان روش‌های سنتی ارزیابی در محاسبه ریسک حساسیتی را کاهش و از رویکردهای داده‌کاوی جهت ارزیابی ریسک حساسیتی استفاده نمایند تا از این طریق از خطاهای مرتبط با قضاوت‌های انسانی بکاهند. این موضوع به خصوص در ارزیابی ریسک حساسیتی شرکت‌های بزرگتر و پیچیده تر توسط حسابرسان از ضرورت بیشتری برخوردار است. شرکت‌های نرم افزاری هم می‌توانند بدین منظور برنامه‌های مناسبی مبتنی بر شبکه‌های عصبی طراحی و جهت ارزیابی ریسک حساسیتی به موسسات حساسیتی ارائه نمایند.

به پژوهشگران نیز پیشنهاد می‌شود بحث حساسیتی مبتنی بر ریسک را در شرکت‌های موجود در صنایع مختلف با استفاده از سایر الگوریتم‌هایی که در سال‌های اخیر کارایی آن به اثبات رسیده مثل الگوریتم مورچگان، کرم شب تاب، ژنتیک و رقابت استعماری انجام دهند و با نتایج این پژوهش مقایسه نمایند.

فهرست منابع

الف - منابع فارسی:

۱. آذر، عادل؛ مومنی، منصور. (۱۳۹۵). آمار و کاربرد آن در مدیریت، جلد دوم، چاپ بیستم، تهران: انتشارات سمت.
۲. اسماعیلی، مهدی. (۱۳۹۱). مفاهیم و تکنیک‌های داده کاوی، انتشارات نیاز دانش.
۳. برزیده، فرخ، نیکخواه بهرامی، زهرا. (۱۳۸۶). ارزیابی حسابرسان از ریسک ذاتی و کنترل. مطالعات تجربی حسابداری مالی، دوره ۵، شماره ۱۸، صص ۸۱-۱۰۴.
۴. پورحیدری، امید؛ اعظمی، زینب. (۱۳۸۹). شناسایی نوع اظهار نظر حسابرسان با استفاده از شبکه‌های عصبی. دانش حسابداری، دوره ۱، شماره ۳، صص ۹۷-۷۷.
۵. دستگیر، محسن؛ شفیع سردهشت، مرتضی. (۱۳۹۰). فناوری داده کاوی رویکردی نوین در حوزه مالی، فصلنامه دانش حساسیتی، دوره ۱۱، شماره ۵، صص ۱۶-۱۵.
۶. ربیعی، افسانه؛ حمیدی، الهام؛ مکارم، ناصر. (۱۳۹۷). اصول حساسیتی، جلد اول، تهران، نشر مرکز تحقیقات تخصصی حسابداری و حساسیتی سازمان حساسیتی.
۷. طلوعی اشلقی، عباس؛ سقایی، عباس؛ خورسندی کریمی، سارا. (۱۳۸۹). پیش بینی فروش فیلم‌های سینمایی

- در ایران با استفاده از شبکه‌های عصبی و مقایسه آن با روش‌های آماری، مطالعات رسانه ای، دوره ۵، شماره ۱۱، ص ۱۸.
۸. فروغی، داریوش؛ یادگاری، سعید. (۱۳۸۹). کاربرد شبکه‌های عصبی مصنوعی در حسابداری. فصلنامه علمی حسابداری و مدیریت مالی، شماره ۴، صص ۵۸-۳۱.
 ۹. قربانی، سعید؛ آقایی، محمدعلی؛ احمدیان، وحید؛ نیکزادقادی کلایسی، مهدیس. (۱۳۹۳). بررسی نارسایی‌های مدل حسابداری مبتنی بر سیستم و امکان جایگزینی آن با مدل حسابداری مبتنی بر ریسک در ایران. فصلنامه دانش حسابداری، دوره ۱۴، شماره ۵۷، صص ۱۴۶-۱۲۹.
 ۱۰. کمیته تجدید نظر دستورالعمل حسابداری. (۱۳۹۸). دستورالعمل حسابداری با نگرش خطر حسابداری، تهران، نشر مرکز تحقیقات تخصصی حسابداری و حسابداری سازمان حسابداری
 ۱۱. مسیحی، محمد؛ یعقوب نژاد، احمد؛ کیقبادی، امیرضا؛ ترابی، تقی. (۱۳۹۸). استفاده از تکنیک‌های داده کاوی در ریسک مالیاتی، فصلنامه علمی پژوهشی دانش سرمایه گذاری، دوره ۸، شماره ۳۲.
 ۱۲. مطیع قادر، حبیب؛ لطفی، شهریار؛ سید افهلان، میر مهدی. (۱۳۸۹). مروری بر برخی از روش‌های بهینه سازی هوشمند، شبستر: انتشارات دانشگاه آزاد اسلامی شبستر.
 ۱۳. مکیان، سید نظام الدین؛ کریمی تکلو، سلیم. (۱۳۸۸). پیش بینی ورشکستگی شرکت‌های تولیدی اولیه با استفاده از شبکه‌های عصبی، فصلنامه اقتصاد مقداری، دوره ۱۶، شماره ۱، صص ۱۴۴-۱۲۰.
 ۱۴. وکیلی فرد، حمیدرضا؛ صلاحی نژاد، مریم. (۱۳۸۸). تبیین و آزمون مدل حسابداری مبتنی بر ریسک در حسابداری عملیاتی، فصلنامه آینده پژوهی مدیریت (پژوهش‌های مدیریت)، دوره ۲۰، شماره ۸۳، صص ۵۴-۳۳.
 ۱۵. همتی، داود؛ عرب صالحی نصرآبادی، مهدی؛ طلوعی اشلقی، عباس. (۱۳۹۹). ارزیابی ریسک حسابداری با استفاده از رویکرد داده کاوی، فصلنامه دانش حسابداری و حسابداری مدیریت، سال ۹، شماره ۳۴، صص ۱۶۷-۱۵۷.

ب- منابع خارجی:

1. Amani, A. F., Fadlalla, M. A., (2017), Data mining applications in accounting: A review of the literature and organizing framework, International Journal of Accounting Information Systems, 24, pp. 32-58.
2. Baldwin, A.A., Brown, C. E., Trinkle, B.S., (2006), Opportunities for artificial intelligence development in the accounting domain: the case for auditing. Intelligent Systems in Accounting finance and Management, 14(3), pp.77-86.
3. Bell, T. B. , Peecher, M. E. , and Solomon, I., (2005) , The 21st century public company audit: Conceptual elements of KPMG's global audit methodology. Publisher, KPMG, LLP.
4. Calderon ,T.G., and Cheh J.J., (2002), 'A roadmap for future neural networks research in auditing and risk assessment', International Journal of Accounting Information Systems , 3, (4), pp. 203-236.
5. Chang, S., shih, D., & Hawang, C., (2008) . The development of audit detection risk assessment system: Using the fuzzy theory and audit risk model. Expert Systems with applications, Vol. 35(1), pp. 1053-1067.
6. Charles Vellutini, Georges Casamatta, Jean-François Morazzani, (2016), Risk-Based Audits: Principles and Implementation, Available in www.ecopa.com.
7. Chen, S., C., Huang, M., Y., (2011), Constructing credit auditing and control & management model with data mining technique, Expert Systems with Applications, 38(5), pp. 5359-5365.
8. Guzallbey, I. H., Cevik, E. A., (2006). Prediction of web crippling strength of cold-formed steel sgeeting using neural Network , Journal of Constructional Steel Research. Vol. 62, pp.962-973
9. Han, J., Kamber, M., Pei, J., (2006) , Data Mining: Concepts and Techniques, A book

- volume in The Morgan Kaufmann Series in Data Management Systems.
10. HuaPing.W.,(2021)., The BP Neural Network with AdamOptimizer forPredicting Audit Opinions of Listed Companies,. IAENG International Journal of Computer Science, Vol. 48, Issue 2
 11. Ila, D .,Shantanu, D ., Bijan, R., (2017) , Detecting Financial Restatements Using Data Mining Techniques, Expert Systems With Applications, 39, pp. 10140–10152.
 12. Jeffrey, W., Seifert ., (2004) , Data Mining: An Overview. Available on line At: Www.Fas.Org/Irp/Crs/RI31798.Pdf.
 13. Kennedy, J., Eberhart, R.C. , (1995), A new optimizer using particle swarm theory. MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science, **Conference Location:** Nagoya, Japan.
 14. Kirkos, E., Spathis, C. and Manolopoulos, Y., (2007), 'Data Mining techniques the detection of fraudulent financial statements', Expert Systems with Applications, Vol. 32, Issue 4, pp. 995-1003.
 15. Mathaba, T., Xia, X. and Zhang, J.,(2014) , Analysing the economic benefit of electricity price forecast in industrial load scheduling. Electric Power Systems Research, Vol. 116, pp.158-165.
 16. Nipanikar, S.I., V. Hima Deepthi., and N. Kulkarni ., (2018), A sparse representation based image steganography using Particle Swarm Optimization and wavelet transform. Alexandria Engineering Journal, Vol. 57(4) ,pp. 2343-2356.
 17. Phuong ,Thao Cao ., Hoang, Tung Nguyen., Thi, Hau Nguye ., (2019), Construction Auditing Risk Detection Using Neural Network, Science, Engineering & Education, Vol. 4, (1), pp.39-44.
 18. Prasad, Y., K.K. Biswas, and M. Hanmandlu., (2018), A recursive PSO scheme for gene selection in microarray data. Applied Soft Computing, Vol. 71 ,pp. 213-225.
 19. Sabau, E. M., Sabau, A. S., Budacia, L. C., Sgârdea, F. M., (2011),Data mining life cycle in fraud auditing, MCBANTA'11: Proceedings of the 12th WSEAS international conference on Mathematics and computers in biology, business and acousticsApril 2011, pp. 55–59.
 20. Sirikulvadhana, S., (2002) , Data Mining As A Financial Auditing Tool, M.Sc. Thesis in Accounting , Swedish School of Economics and Business Administration.
 21. Wang, J. , Yang, G.S., James ., (2007) , Data Mining Techniques for Auditing Attest Function andFraud Detection :Journal of Forensic & Investigative Accounting , Vol.1 (1).
 22. Wyrobeka, J.,(2020),Application of machine learning models and artificial intelligence to analyze annual financial statements to identify companies with unfair corporate culture, . Procedia Computer Science, Vol. 176, pp. 3037-3046.
 23. Yang, H. and F. Wang .,(2019), Wireless Network Intrusion Detection Based on Improved Convolutional Neural Network. IEEE Access, Vol. 7, pp. 64366-64374.
 24. Zhang. X.,(2021), Construction and Simulation of Financial AuditModel Based onConvolutional Neural Network,. Computational Intelligence and Neuroscience,. Computational Intelligence and Neuroscience, Volume 2021, Article ID 1182557, 11 pages