



دوره پانزدهم، شماره پاییز و زمستان ۱۴۰۱

مجله فناوری اطلاعات در طراحی مهندسی

Information Technology in Engineering Design

<http://ited.sinaweb.net>

رویکرد کاهش ریسک در مؤسسات مالی برای انتخاب متقاضیان تسهیلات با استفاده از یک پایگاه

داده استاندارد بر پایه یادگیری عمیق

حامد حدادی^(۱) سید ناصر رضوی^{(۱)*، (۲)} امین بابا زاده سنگر^(۳)

(۱) گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

(۲) دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران*

(۳) گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

تاریخ دریافت: ۱۴۰۲/۰۱/۲۶ تاریخ پذیرش: ۱۴۰۲/۰۵/۰۱

چکیده

در مؤسسات مالی، بانک‌ها و مؤسسات کارآفرینی که تسهیلات اشتغال به مشتریان خود پرداخت می‌کنند، مسائل متعددی را قبل از اعطای تسهیلات مورد بررسی قرار می‌دهند. در این میان، مهم‌ترین و پراهمیت‌ترین موضوع برای یک سیستم مالی، ارزیابی توان مشتریان در بازپرداخت تسهیلات می‌باشد. انتخاب درست متقاضیان تسهیلات، با استفاده از روش‌های سنتی انجام می‌شود که این روش‌ها مستعد خطا می‌باشند. امروزه با توسعه یادگیری ماشین، می‌توان انتخاب درست متقاضیان را با دقت بیشتری انجام داد. در سال‌های اخیر روش‌هایی خودکار و نیمه‌خودکار با استفاده از رویکردهای یادگیری ماشین ارائه شده است. با این حال، مشکل عمده مطالعات پیشین انتخاب ویژگی‌های متمایزکننده و عدم وجود یک پایگاه داده جامع است. این مطالعه با هدف رفع کاستی‌های مطالعات پیشین، یک مدل تصمیم‌گیری توسعه‌یافته با در نظر گرفتن الگوهایی از مشتریان موفق و غیر موفق در ۴ حوزه مختلف پیش‌بینی وضعیت نظارت، وضعیت تسهیلات، مدت‌زمان فعالیت و تعداد اشتغال ایجاد شده، ارائه شده است. در این مطالعه، یک پایگاه داده جامع بر پایه استانداردهای موجود جمع‌آوری شده و یک مدل شبکه عصبی عمیق برای استخراج ویژگی‌ها از داده‌های ورودی، طراحی شده است. صحت نتایج به‌دست‌آمده در این مطالعه برای چهار حوزه پیش‌بینی وضعیت نظارت، پیش‌بینی وضعیت تسهیلات، پیش‌بینی تعداد شغل ایجاد شده و پیش‌بینی مدت فعالیت به ترتیب ۸۱، ۵۸، ۷۵ و ۵۶ درصد است که در مقایسه با مطالعات پیشین بالاتر بوده و اثربخشی بیشتری دارد. با توسعه روش پیشنهادی و راه‌یابی مطالعه حاضر به حوزه‌های کاربردی و عملی، می‌توان متقاضیان مطلوب تسهیلات را به‌صورت خودکار و با صحت بیشتری ارزیابی و انتخاب نمود.

کلمات کلیدی: انتخاب خودکار متقاضیان تسهیلات، ارزیابی کسب‌وکار، یادگیری ویژگی، شبکه عصبی عمیق

*عهده‌دار مکاتبات:

سید ناصر رضوی

نشانی: گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران

دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

پست الکترونیکی: naser.razavi@adaptcentre.ie

ارزیابی متقاضیان تسهیلات توسط مؤسسات مالی مختلف به منظور بازپرداخت تسهیلات ارائه شده از جمله مسائل مهمی هستند که باید به آن توجه شود. امروزه ارزیابی متقاضیان به شیوه‌های سنتی توسط کارشناسان انجام می‌پذیرد [۱]. ارزیابی متقاضیان به شیوه سنتی امری زمان‌بر بوده و مستعد خطای انسانی می‌باشد. همچنین، انتخاب متقاضیان مطلوب به شیوه سنتی سبب کاهش دقت تشخیص خواهد شد [۲]. بر اساس مطالب گفته شده لازم است تا انتخاب متقاضیان به منظور مقابله با رانت‌خواری توسط کارشناسان ارزیاب و افزایش دقت تشخیص، به شیوه خودکار انجام پذیرد. امروزه با تکیه بر یادگیری ماشین، این امر محقق شده است و بر همین اساس پژوهش‌های بسیاری در این زمینه انجام پذیرفته است. با این حال، چالش عمده در الگوریتم‌های مربوط به مسائل مالی، انتخاب ویژگی‌های متمایزکننده از یکدیگر است [۲، ۳]. در اکثر مطالعات پیشین مسائل مالی (پیش‌بینی ورشکستگی، امتیازدهی اعتباری، ارزیابی ریسک و ارزیابی کسب‌وکار متقاضیان) از روش‌های مرسوم آماری و پردازشی، ویژگی‌هایی استخراج شده؛ سپس با روش‌های کاهش ویژگی، ویژگی‌های مطلوب و بهینه انتخاب می‌شدند. استخراج این ویژگی‌ها به صورت دستی در مسائل مالی، باعث پیچیدگی بار محاسباتی الگوریتم خواهد شد. به علاوه، ویژگی‌های مطلوب و بهینه در یک مسئله ممکن است برای مسئله‌ای دیگر، ویژگی بهینه‌ای محسوب نشود. بنابراین، استفاده از روشی که بتواند ویژگی‌های مناسب را بسته به نوع مسئله و داده یاد بگیرد؛ امری ضروری است. همچنین، چالش دوم در تحقیقات پیشین این است که بر روی مسائل مالی مربوط به ارزیابی کسب‌وکار متقاضیان، مطالعه قابل توجهی انجام نشده است و همچنین پایگاه داده جامعی در این خصوص موجود نیست. علاوه بر این، از آنجاکه شبکه‌های عمیق نیاز به داده‌های نسبتاً زیادی برای فرآیند آموزش دارند، پایگاه داده‌های موجود مربوط به ارزیابی کسب‌وکار متقاضیان به علت کمبود نمونه‌های آموزشی برای رویکردهای یادگیری عمیق مناسب نیست؛ این مسئله نکته کلیدی این مطالعه است. در این مطالعه تلاش شده است تا بر چالش‌های بیان شده فائق آییم. بدین ترتیب، در این پژوهش یک پایگاه داده جامع مالی مطابق با استانداردهای لازم و متناسب با رویکردهای یادگیری عمیق جمع‌آوری شده است. همچنین، چهار نوع پیش‌بینی جدید و پراهمیت در مؤسسات مالی و کارآفرینی شامل اجرای طرح، بازپرداخت تسهیلات، مدت‌زمان فعالیت کسب‌وکار و تعداد اشتغال ایجاد شده با معماری پیشنهادی مبتنی بر یادگیری عمیق طراحی و پیاده‌سازی شده است تا داده‌های خام اولیه را به منظور یادگیری ویژگی‌ها به صورت خودکار پردازش کند. نوآوری‌های مربوط به این مطالعه به شرح زیر است:

۱. جمع‌آوری یک پایگاه داده جامع با چهار نوع پیش‌بینی جدید و پراهمیت در مؤسسات مالی و کارآفرینی شامل

اجرای طرح، بازپرداخت تسهیلات، مدت‌زمان فعالیت کسب‌وکار و تعداد اشتغال ایجاد شده.

۲. طراحی یک معماری سفارشی شده بر اساس شبکه‌های یادگیری عمیق.

۳. دستیابی به بالاترین صحت عملکرد در مقایسه با پژوهش‌های اخیر.

ادامه مقاله به شرح زیر سازمان یافته است: بخش دوم به مرور ادبیات پیشین می‌پردازد. بخش سوم مجموعه پایگاه داده مالی جمع‌آوری شده را تشریح می‌کند. همچنین پیش‌زمینه ریاضی مربوط به شبکه‌های عصبی عمیق در این بخش به اختصار توضیح داده می‌شود. بخش چهارم بر روی پیش‌پردازش دادگان، معماری شبکه عمیق پیشنهادی، فرآیند آموزش و ارزیابی مجموعه دادگان تمرکز دارد. بخش پنجم مربوط به نتایج شبیه‌سازی و مقایسه با پژوهش‌های پیشین است. در نهایت بخش ششم مربوط به نتیجه‌گیری می‌باشد.

مطالعات در زمینه مسائل مالی به ۴ دسته اصلی تقسیم می‌شوند: پیش‌بینی ورشکستگی^۱، امتیازدهی اعتباری^۲، ارزیابی ریسک^۳ و ارزیابی کسب‌وکار^۴ متقاضیان. در ادامه هر یک از این دسته‌ها مورد بررسی قرار می‌گیرد [۱]. یکی از خطرناک‌ترین مشکلات در شرکت‌ها، مؤسسات مالی و حسابداری ورشکستگی است. بنابراین، مطالعات اخیر بر پیش‌بینی وضعیت شرکت‌های مالی در یک بازه زمانی خاص متمرکز شده‌اند. ترازنامه، صورت درآمد، سابقه پرداخت وام‌ها، تعهدات نسبت به سازمان‌های مالیاتی و روابط پیچیده تجاری، منابع قابل توجهی هستند که به‌منظور افزایش دقت مدل‌های پیش‌بینی ورشکستگی به‌طور گسترده مورد مطالعه قرار گرفته است [۲، ۳].

یکی دیگر از پارامترهای حیاتی مهم در روابط کسب‌وکار با وام‌دهنده‌ها مانند بانک‌ها، مؤسسات مالی و شرکت‌های کارت اعتباری، امتیازدهی اعتباری است. این عدد مهم آماری با تجزیه و تحلیل و ارزیابی اطلاعات مربوط به ویژگی‌های مالی هر متقاضی مانند تاریخچه اعتباری، دوره سپرده‌گذاری وام و سایر داده‌های مرتبط به دست می‌آید. به‌طور کلی، مدل‌های امتیازدهی اعتباری برای ارزیابی ریسک بالقوه یک وام با تخمین مقدار احتمالی استفاده می‌شود که با تعیین مقدار سطح آستانه، سه نوع مدل را مشخص می‌کند: درخواست اعتباری پذیرفته‌شده، محدودیت مبلغ اعتباری یا درخواست اعتباری رد شده [۴-۸].

دسته سوم در رابطه با مؤسسات مالی ارزیابی ریسک می‌باشد که ثابت شده است این روزها نقش تعیین‌کننده‌ای در تعیین اعتبار و سودآوری عملکرد بانک‌ها دارد. صنعت بانکی با ارزیابی، پیش‌بینی احتمال و مدیریت ریسک در موضوعات مختلف مالی از جمله عدم اعتبار، زیان وام و غیره، احتمال ضرر را کاهش می‌دهد. علاوه بر این، یک مدل ارزیابی ریسک بانکی خوب، سطح متقاضیان نامطمئن، زمان و هزینه فرآیند تصمیم‌گیری وام و تهدیدات منفی را کاهش می‌دهد [۹-۱۱].

آخرین و نادیده گرفته‌ترین مسئله در مطالعات مالی، ارزیابی کسب‌وکار است که احتمال موفقیت یک کسب‌وکار را بر اساس منطقه راه‌اندازی آن تعیین می‌کند. تمرکز اصلی در منطقه راه‌اندازی کسب‌وکار^۵، اهمیت قابل توجه مکان راه‌اندازی کسب‌وکار و وضعیت آن از قبیل مشاغل و صنایع مرتبط، وضعیت آب و هوایی و ظرفیت کارآفرینی برای دستیابی به سود رضایت‌بخش است. در ادامه تحقیقات اخیر که در زمینه مطالعات مالی انجام شده است، به صورت کامل مورد بحث و بررسی قرار می‌گیرد. زوریک و همکاران [۱] یک مجموعه داده جدید شامل ۱۰۰۰ نمونه از نسبت‌های مالی ۲۰ شرکت با ویژگی‌های آماری با استفاده از طبقه‌بندهای ماشین بردار پشتیبان^۶ (SVM)، جنگل تصادفی^۷ (RF) و روش کمترین مربعات^۸ ارائه دادند و بهترین مدل را شناسایی کردند. سوئی و همکاران [۲] از یادگیری عمیق برای تخمین ورشکستگی در دو مجموعه پایگاه داده مالی مختلف استفاده کردند. بدین منظور، این پژوهشگران در معماری پیشنهادی خود از شبکه اتوانکدر^۹ به‌منظور استخراج ویژگی‌های بهینه استفاده کردند و لایه سافت مکس^{۱۰} را برای طبقه‌بندی به‌کار گرفتند. عملکرد برتر روش پیشنهادی آن‌ها با مقایسه جامع با

^۱ Bankruptcy Prediction

^۲ Credit Scoring

^۳ Risk Assessment

^۴ Business Evaluation

^۵ Business Startup Area

^۶ Support Vector Machine (SVM)

^۷ Random Forest (RF)

^۸ Least-Squares

^۹ Autoencoder

^{۱۰} Softmax

رگرسیون لجستیک^{۱۱} (LR)، درخت تصمیم‌گیری^{۱۲} (DT)، شبکه عصبی مصنوعی^{۱۳} (ANN) و در مجموعه داده‌های Darden و Polish نشان داده شده است. اوبیر و همکاران [۳] پژوهش خود را بر روی یک مدل جداساز خطی انجام داده‌اند که احتمال عدم پرداخت وام بانک سرمایه در کنیا را که شامل ۱۰۰۰ نمونه با استفاده از مدل LR است، تخمین می‌زند. ویژگی‌های مختلف هر متقاضی از جمله شرایط اشتغال، مبلغ وام، سابقه اعتباری و غیره در این پژوهش نظر گرفته شده است. در این پژوهش، رگرسیون لجستیک با رویکرد یادگیری ماشین تحت نظارت^{۱۴}، برای پیش‌بینی عدم پرداخت وام در مؤسسات مالی پیشنهاد شد. آبلان و همکاران [12] پژوهشی را بر روی مسائل امتیازدهی اعتباری با استفاده از روش CDT^{۱۵} و روش‌های طبقه‌بندی انجام دادند و روش پیشنهادی خود را با طبقه‌بند درخت تصمیم‌گیری مقایسه کردند. معیارهای اندازه‌گیری^{۱۶} AUC و محاسبه دقت^{۱۷} در این پژوهش به‌عنوان معیارهای مقایسه‌ای مورد استفاده قرار گرفت. بکو و همکاران [13] یک رویکرد مبتنی بر یادگیری ماشین را برای محاسبه امتیاز اعتباری در سه مجموعه داده مختلف اعتبار استرالیا، اعتبار آلمان و توماس ارائه کردند. این پژوهشگران نتایج پژوهش خود را با طبقه‌بندهای ANN، SVM، K-Nearest Neighbor (K-NN)^{۱۸}، LR و درخت تصمیم‌گیری مقایسه کردند و به نتایج امیدوارکننده‌ای دست یافتند. خیا و همکاران [14] روی امتیازدهی اعتباری ناهمگن با استفاده از روش‌های طبقه‌بندی مختلف مثل SVM، RF و گرادیان تقویتی حداکثر^{۱۹} بر روی چهار دیتاست شامل مجموعه داده آلمان با ۱۰۰۰ نمونه و ویژگی، مجموعه داده استرالیا با ۶۹۰ نمونه و ۲۴ ویژگی، مجموعه داده P2P-A با ۱۴۲۱ نمونه و ۱۷ ویژگی و مجموعه داده P2P-B با ۲۶۴۲ نمونه و ۱۱ ویژگی کار کردند و به نتایج امیدوارکننده‌ای دست یافتند. لوو و همکاران [16] از مدل‌های طبقه‌بندی اعتبار سنجی در مجموعه داده شامل ۶۶۱ مشتری از آمریکای شمالی، آسیا و اروپا با استفاده از رویکرد یادگیری عمیق^{۲۰} استفاده کردند. این پژوهشگران پژوهش خود را با روش‌های استخراج ویژگی کلاسیک و طبقه‌بندهای پرسپترون چندلایه^{۲۱}، SVM، LR چندلایه و شبکه‌های باور عمیق (DBN)^{۲۲} مقایسه کردند که در بررسی تجربی، روش یادگیری عمیق بهترین عملکرد را از خود نشان داد. بائو و همکاران [۹] از یک روش ترکیبی یادگیری نظارت‌شده و بدون نظارت^{۲۳} برای پیش‌بینی مسائل مربوط به ریسک اعتباری استفاده کردند. بدین منظور، این پژوهشگران مجموعه داده‌های اعتباری چین، آلمان و استرالیا را به‌کار گرفتند. همچنین، آن‌ها الگوریتم پیشنهادی خود را با هفت روش یادگیری ماشین شامل درختان تصمیم

^{۱۱} Logistic Regression (LS)

^{۱۲} Decision Tree (DT)

^{۱۳} Artificial Neural Network (ANN)

^{۱۴} Supervised Learning

^{۱۵} Credal Decision Tree (CDT)

^{۱۶} Area Under the Curve (AUC)

^{۱۷} Precision

^{۱۸} K-Nearest Neighbor (K-NN)

^{۱۹} Gradient Boosting

^{۲۰} Deep Learning (DL)

^{۲۱} Multilayer Perceptron

^{۲۲} Deep Belief Networks (DBN)

^{۲۳} Unsupervised Learning

گرادیان تقویتی^{۲۴}، SVM، K-NN، RF، DT، LR و ANN مقایسه کردند و به نتایج امیدوارکننده‌ای دست یافتند. پتروپولوس و همکاران [۱۱] رویکرد جدیدی مبتنی بر یادگیری عمیق و گرادیان تقویتی حداکثر را برای برآورد ریسک اعتباری سیستم بانکی یونان که حاوی بیش از ۲۰۰۰۰۰ پرونده است، ارائه کردند. علاوه بر این، برای افزایش دقت برآورد ریسک اعتباری، روش‌های داده‌کاوی را با روش پیشنهادی خود ترکیب کردند. ارزیابی این مطالعه نشان داد که روش‌های گرادیان تقویتی حداکثر و شبکه‌های عصبی یادگیری عمیق در مقایسه با جداساز خطی و رگرسیون لجستیک، عملکرد بهتری دارند. چلیک و همکاران [۱۶] از شبکه‌های عصبی مصنوعی برای نشان دادن یک مدل پیش‌بینی استفاده کردند که می‌توانست ریسک‌ها و بحران فرآیند بانکی را بر روی مجموعه داده‌های به‌دست‌آمده از سیستم تحویل داده الکترونیک^{۲۵} بانک مرکزی جمهوری ترکیه^{۲۶} پیش‌بینی کند. شومو و همکاران [۱۷] با استفاده از روش‌های یادگیری ماشین مانند SVM، RF و رگرسیون لجستیک (LR) بر روی یک مدل بهینه برای کاهش ریسک اعتباری کار کردند. مدل پیشنهادی با استفاده از ۳۲ ویژگی مختلف در مجموعه داده "loan_status" که شامل ۳۸۶۶۱ نمونه است، اجرا شد. نتایج ارزیابی، عملکرد بهتر طبقه‌بند SVM را نشان می‌دهد. با مرور در ادبیات گذشته، مشکلات و چالش‌های مطرح‌شده در بخش مقدمه اثبات می‌شود. در بخش بعد مواد و روش‌های مورد استفاده در این مطالعه مورد بررسی قرار می‌گیرد.

۳- مواد و روش‌ها

در این بخش در ابتدا مجموعه پایگاه دادگان جمع‌آوری‌شده به‌طور کامل شرح داده می‌شود، سپس پیش‌زمینه ریاضی مربوط به شبکه‌های عصبی عمیق بررسی خواهد شد.

۳-۱- پایگاه دادگان جمع‌آوری‌شده

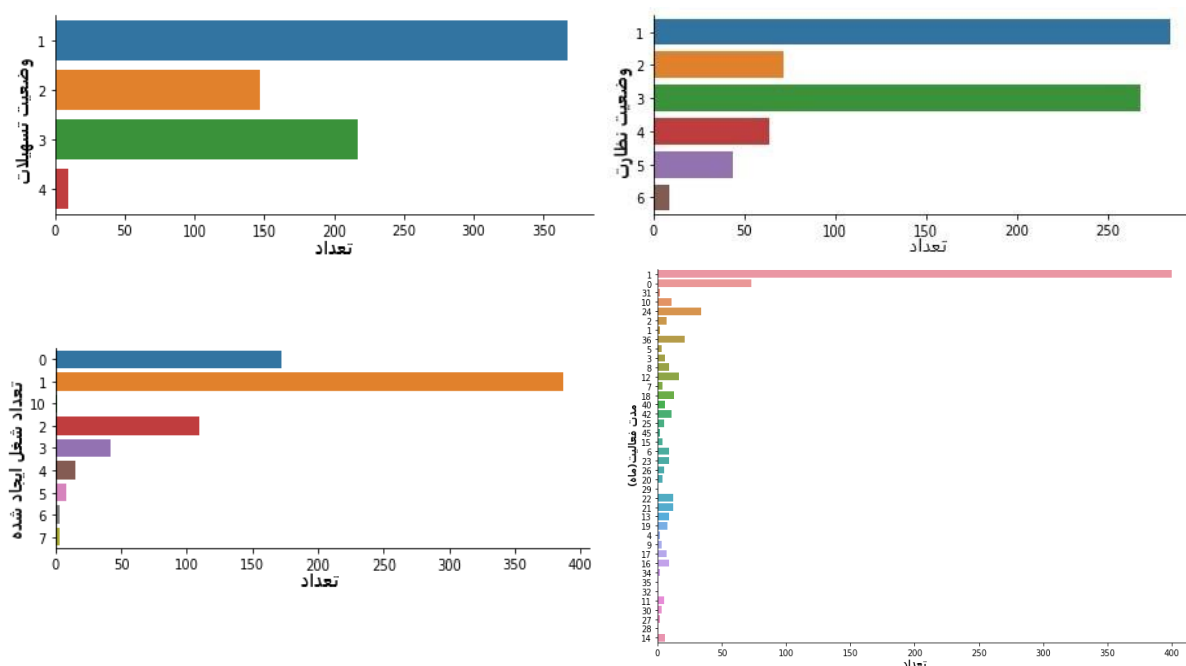
در این مطالعه به‌منظور ارزیابی دقیق‌تر روش پیشنهادی، یک پایگاه داده جامع مطابق با استانداردهای لازم بر اساس تسهیلات ارائه‌شده به متقاضیان جمع‌آوری شده است. مطابق با مطالب بیان‌شده، این پایگاه داده شامل ۷۴۱ رکورد از تسهیلات ارائه‌شده توسط صندوق کارآفرینی شهر تبریز به متقاضیان تسهیلات در سال‌های ۱۳۹۳ تا ۱۳۹۶ است که بر اساس ۲۴ ویژگی مختلف متقاضیان از جمله وضعیت تأهل، جنسیت، سطح مدرک تحصیلی، رشته تحصیلی، مدرک مهارتی، رشته مدرک مهارتی، مدرک مرتبط یا نامرتب، سابقه کار، وضعیت سرپرستی، نوع سرپرستی، آورده نقدی، سابقه بانکی، سن، منطقه بخش اقتصادی، امتیاز مزیت نسبی، نرخ تورم، بازار محور بودن، نوع طرح، سال اخذ واحد، نوع کسب‌وکار، مرجع معرفی، جواز کسب، نوع مالکیت و محل اجرا جمع‌آوری‌شده و سازمان یافته است. باید خاطر نشان کرد که هرکدام از این ویژگی‌ها دارای چند زیر ویژگی می‌باشند؛ به‌عنوان مثال، برای ویژگی وضعیت تأهل دو زیر ویژگی یا حالت مجرد و متأهل وجود دارد که بر همین اساس در مجموع ۷۴ ویژگی کلی از دادگان استخراج شده است. بر اساس ویژگی‌های یادشده، تسهیلات توسط صندوق کارآفرینی به متقاضیان ارائه شده است و پس از ارائه تسهیلات به ۷۴۱ متقاضی، وضعیت نظارت، مدت فعالیت، تعداد شغل ایجادشده و وضعیت تسهیلات به‌صورت کامل استخراج شده و در دسترس است. توزیع فراوانی مربوط به ۴ حوزه پیش‌بینی؛ الف) وضعیت نظارت، ب) مدت فعالیت، ج) تعداد شغل ایجادشده و د) وضعیت تسهیلات، برای کل مجموعه دادگان جمع‌آوری‌شده در شکل ۱ نمایش داده شده است. مطابق با شکل ۱، برای وضعیت نظارت ۶ کلاس مختلف راه‌اندازی، عدم راه‌اندازی، تعطیلی بعد از

^{۲۴} Gradient Boosting Decision Tree

^{۲۵} Electronic Data Delivery System

^{۲۶} Central Bank of the Republic of Turkey

اخذ وام، توسعه، عدم توسعه و شراکتی موجود است. همچنین، بر اساس مدت فعالیت هر کسب و کار بعد از راه اندازی (برحسب ماه) تا زمان جمع آوری دادگان ۵۳ درصد از کسب و کار همچنان فعال بوده و ۴۷ درصد از این کسب و کارها بعد از چند ماه متوقف شده اند. علاوه بر این، مطابق با شکل ۱، برای وضعیت تسهیلات در کل مجموعه داده ۴ کلاس مختلف شامل حالت مناسب، نسبتاً مناسب (سررسید گذشته)، نسبتاً نامناسب (معوق) و نامناسب (مشکوک الوصول) وجود دارد. همچنین، تعداد شغل های ایجاد شده در ۸ کلاس مختلف دسته بندی شده اند. بر همین اساس، همان طور که از نمودار مشخص است، بیش از نیمی از شغل ها زمینه اشتغال را فقط برای یک نفر فراهم کرده است و هیچ کسب و کاری نتوانسته است برای بیش از هشت نفر اشتغال زایی انجام دهد. لازم به ذکر است که دادگان جمع آوری شده در بستر [github^{۲۷}](https://github.com/haddadihamed/Entrepreneurship-Fund-Dataset/blob/main/tabrizdataset.xlsx) برای استفاده پژوهشگران قابل دسترسی است.



شکل (۱): توزیع فراوانی مربوط به ۴ حوزه پیش بینی مختلف.

۲-۳- شبکه های عصبی عمیق

شبکه عصبی عمیق، در واقع یک شبکه عصبی معمولی بهبود یافته است. در این شبکه، چندین لایه با روشی قدرتمند در کنار هم آموزش می بینند [۱۸]. این روش، بسیار کارآمد بوده و یکی از رایج ترین روش ها در کاربردهای مختلف بینایی ماشین است. همانند شبکه عصبی معمولی، تصمیم خروجی نهایی شبکه عمیق بر اساس وزن و بایاس لایه های قبلی در ساختار شبکه است. برخی از مهم ترین شبکه های عصبی عمیق عبارت اند از؛ شبکه عصبی پیش خور عمیق^{۲۸}، شبکه عصبی کانولوشنال^{۲۹}، شبکه عصبی خود رمزنگار^{۳۰} و شبکه حافظه کوتاه مدت^{۳۱} است که در ادامه شبکه عصبی پیش خور عمیق به صورت خلاصه توضیح داده شده است.

^{۲۷} <https://github.com/haddadihamed/Entrepreneurship-Fund-Dataset/blob/main/tabrizdataset.xlsx>

^{۲۸} Feedforward Neural Network

^{۲۹} Convolutional Neural Network (CNN)

^{۳۰} Deep Autoencoder

^{۳۱} Long Short Term-Memory

در بسیاری از مسائل پیچیده ریاضی که به حل معادلات بغرنج غیرخطی منجر می‌شود، شبکه عصبی پیش‌خور می‌تواند به‌سادگی با تعریف اوزان و توابع مناسب مورد استفاده قرار گیرد. در هر شبکه عصبی پیش‌خور، دو مرحله برای آموزش وجود دارد؛ مرحله انتشار پیشرو^{۳۲} (FF) و مرحله پس‌انتشار^{۳۳} (BP) [۱۹]. BP روشی برای محاسبه گرادیان تابع اتلاف نسبت به وزن‌ها است. BP سیگنال‌های خطا را در شبکه در حین آموزش پس‌زده و باعث به‌روزرسانی وزن‌ها می‌شود. در مرحله اول، داده‌های ورودی به شبکه اعمال می‌شود و در نهایت، خروجی شبکه محاسبه می‌گردد. به‌منظور تنظیم پارامترهای شبکه و یا به‌عبارت‌دیگر آموزش شبکه، از نتیجه خروجی جهت محاسبه میزان خطای شبکه استفاده می‌شود. برای این کار، خروجی شبکه با استفاده از یک تابع خطا^{۳۴} با پاسخ صحیح مقایسه شده و به‌این‌ترتیب، میزان خطا محاسبه می‌گردد. در مرحله بعد، بر اساس میزان خطای محاسبه‌شده، مرحله پس‌انتشار آغاز می‌شود. در این مرحله، گرادیان هر پارامتر با توجه به‌قاعده زنجیره‌ای محاسبه‌شده و تمامی پارامترها با توجه به تأثیری که بر خطای ایجادشده در شبکه دارند، به‌روزرسانی می‌شوند. بعد از به‌روزرسانی پارامترها، مرحله بعدی انتشار پیشرو آغاز خواهد شد. بعد از تکرار تعداد مناسبی از این مراحل، آموزش شبکه به پایان می‌رسد. به‌طورکلی، یک شبکه عصبی پیش‌خور از سه لایه اصلی؛ لایه ورودی، لایه‌های پنهان و لایه خروجی که بر پایه لایه تمام‌متصل^{۳۵} (FC) هستند، تشکیل می‌شود. در این شبکه، خروجی هر لایه همان ویژگی‌ها هستند که بعد کمتری نسبت به داده اصلی دارند. در این شبکه هر لایه ویژگی‌های خاصی را یاد می‌گیرد؛ لایه‌های اولیه ویژگی‌های پایه‌ای و سطح پایین و لایه‌های بعدی ویژگی‌های پیچیده و سطح بالا را یاد می‌گیرند. برای جلوگیری از فرآیند بیش‌برازش^{۳۶} و بهبود عملکرد این شبکه می‌توان از لایه‌های حذف تصادفی^{۳۷} و نرمال‌سازی دسته‌ای^{۳۸} نیز استفاده کرد. همچنین در شبکه‌های عصبی نیاز است پس از هر لایه از توابع فعال‌سازی مختلفی به‌فراخور اسلوب مسئله استفاده شود که در ادامه، این لایه‌ها و توابع اجمالاً معرفی می‌شوند.

لایه FC: دارای اتصال کامل به تمام فعال‌سازی‌ها در لایه قبلی است [۱۸].

لایه حذف تصادفی: از این لایه به‌منظور جلوگیری از پدیده بیش‌برازش استفاده می‌شود [۱۹]. نحوه کار آن به این صورت است که در هر مرحله از آموزش، هر نورون با احتمالی از شبکه بیرون انداخته شده؛ به‌طوری‌که نهایتاً یک شبکه کاهش‌داده‌شده باقی می‌ماند.

لایه نرمال‌سازی دسته‌ای: این لایه به‌منظور نرمال‌سازی داده‌ها در داخل شبکه انجام می‌شود [۲۰]. زمانی که محاسبات مختلف روی داده ورودی اعمال شود؛ توزیع داده‌ها تغییر پیدا خواهد کرد. این لایه باهدف کاهش تغییر کوواریانس داخلی، سرعت آموزش شبکه را افزایش و باعث تسریع در همگرایی می‌شود. تبدیل لایه نرمال‌سازی دسته‌ای به شرح رابطه (۱) زیر است:

^{۳۲} Feed Forward

^{۳۳} Backpropagation

^{۳۴} Error Function

^{۳۵} Fully Connected Neural Network (FCNN)

^{۳۶} Overfitting

^{۳۷} Dropout

^{۳۸} Batchnormalization

$$\begin{aligned}\mu_B &= \frac{1}{n} \sum_{i=1}^n y_i^{(l-1)} \\ \sigma_B^2 &= \frac{1}{n} \sum_{i=1}^n (y_i^{(l-1)} - \mu_B)^2 \\ \hat{y}^{(l-1)} &= \frac{y^{(l-1)} - \mu_B}{\sqrt{(\sigma_B^2 + \varepsilon)}} \\ z^{(l)} &= \gamma^{(l)} \hat{y}^{(l-1)} + \beta^{(l)}\end{aligned}\quad (1)$$

که μ_B و σ_B^2 به ترتیب میانگین و واریانس دسته هستند. ε یک ثابت کوچک برای ثبات عددی، l شماره لایه، $y^{(l-1)}$ بردار ورودی به لایه نرمال‌ساز، $z^{(l)}$ بردار خروجی نرمال مربوط به یک نورون، $\gamma^{(l)}$ و $\beta^{(l)}$ به ترتیب پارامترهای مربوط به مقیاس و تغییر نرخ یادگیری هستند.

تابع فعال‌سازی: پس از هر لایه از شبکه عصبی، یک تابع فعال‌سازی اعمال می‌شود. تابع فعال‌سازی یک عملگر است که خروجی را به مجموعه‌ای از ورودی‌ها نگاشت می‌کند و برای غیرخطی کردن ساختار شبکه استفاده می‌شود. برخی از توابع فعال‌ساز عبارت‌اند از: تابع فعال‌ساز سیگموئید^{۳۹}، تابع فعال‌ساز تانژانت هایپربولیک^{۴۰}، تابع فعال‌ساز رلو^{۴۱}.
تابع سافت مکس^{۴۲}: این تابع توزیع احتمالی کلاس‌های خروجی را محاسبه می‌کند. بنابراین، در لایه تمام متصل آخر از تابع سافت مکس برای پیش‌بینی کلاس‌های مربوطه استفاده می‌شود و به فرم رابطه‌ی (۲) قابل تعریف است:

$$p_i = \frac{e^{x_j}}{\sum_k e^{x_k}} \quad \text{for } j = 1, \dots, k \quad (2)$$

که در آن، x ورودی شبکه است و مقادیر خروجی p بین صفر و یک بوده که مجموع آن‌ها برابر با یک است [۲۱].

۴- روش پیشنهادی

در این بخش روش پیشنهادی این مطالعه در زیر بخش‌های پیش‌پردازش دادگان، معماری شبکه و آموزش و ارزیابی دادگان ارائه شده است. بلوک دیاگرام روش پیشنهادی در شکل ۲ نمایش داده شده است. مطابق با بلوک دیاگرام شبکه پیشنهادی، ابتدا پایگاه داده پیشنهادی جمع‌آوری می‌شود. در مرحله دوم، عملیات پیش‌پردازش که شامل مراحل دودویی کردن ویژگی‌ها، نرمالیزه کردن مین-مکس ویژگی‌ها و امتحان کردن حالت دودویی و غیر دودویی ویژگی‌ها است، بر روی دادگان جمع‌آوری شده انجام می‌شود. در مرحله سوم، معماری شبکه عمیق پیشنهادی که شامل انتخاب تعداد لایه‌ها، انتخاب ابعاد فیلترها و غیره است طراحی خواهد شد. در مرحله چهارم، نحوه تخصیص دادگان برای مجموعه‌های آموزش و ارزیابی مشخص می‌شود. در ادامه هر یک از مراحل یادشده، به صورت کامل به همراه جزئیات ارائه خواهد شد.

۴-۱- پیش‌پردازش دادگان

با توجه به ماهیت ناهمگن داده‌ها، پیش‌پردازش‌های زیر انجام پذیرفته است:

۱. دودویی کردن ویژگی‌هایی که دارای حالت گسسته می‌باشند.
۲. نرمالیزه کردن مین-مکس ویژگی‌ها.

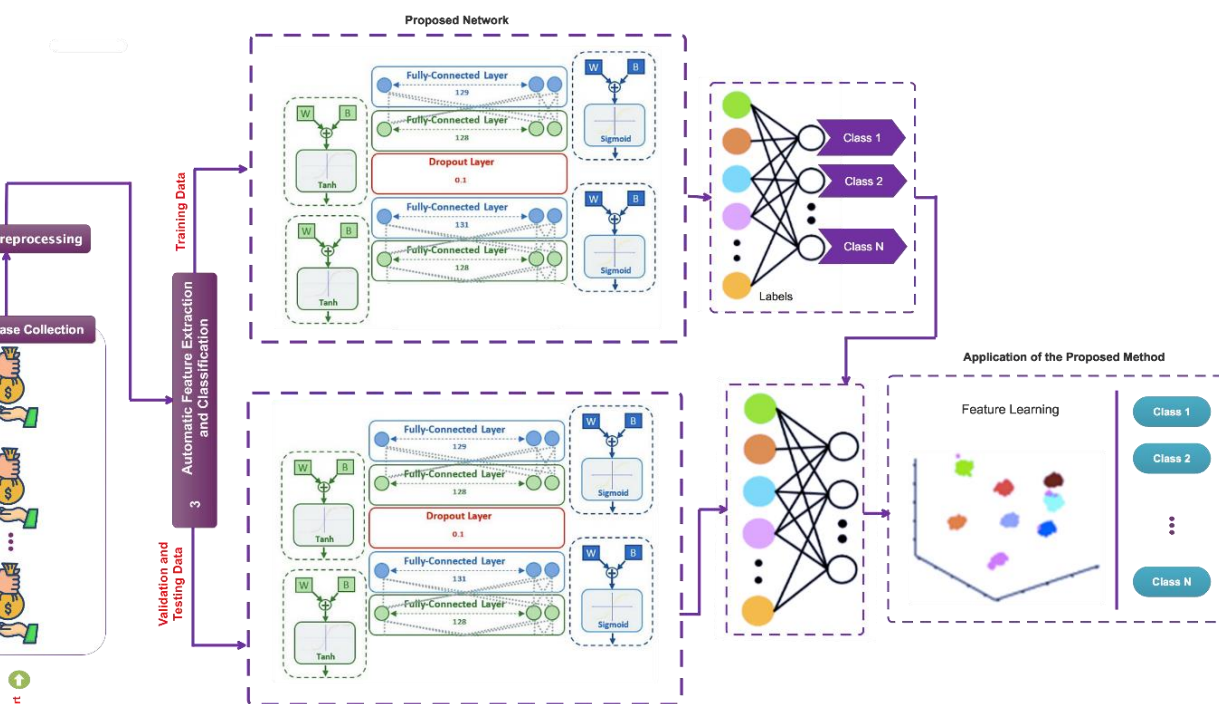
^{۳۹} Sigmoid Function

^{۴۰} Tanh Function

^{۴۱} Relu Function

^{۴۲} Softmax

۳. امتحان کردن حالت دودویی و غیر دودویی جهت پیدا کردن بهترین حالت ممکن برای هر ویژگی.



شکل (۲): بلوک دیاگرام روش پیشنهادی.

۲-۴ - معماری شبکه عمیق پیشنهادی

در این مطالعه، یک شبکه عصبی پیش‌خور عمیق طراحی شده است. در شبکه پیشنهادی از یک‌لایه ورودی جهت اعمال ورودی‌های مسئله و از چهار لایه پنهان و یک‌لایه خروجی برای ارائه پاسخ‌های مسئله استفاده شده است. معماری شبکه پیشنهادی به صورت زیر انتخاب شده است: (۱) ابتدا یک‌لایه FC با تابع فعال‌ساز سیگموئید قرار می‌گیرد. (۲) یک‌لایه FC با تابع فعال‌ساز تانژانت هایپربولیک که پس از آن یک‌لایه حذف تصادفی قرار می‌گیرد. (۳) یک‌لایه FC با تابع فعال‌ساز سیگموئید. (۴) یک‌لایه FC با تابع فعال‌ساز تانژانت هایپربولیک. (۵) یک‌لایه FC با تابع غیرخطی سافت‌مکس برای دسترسی به لایه خروجی استفاده می‌شود. همان‌طور که ملاحظه می‌شود، کاهش ابعاد در لایه‌های پنهان از ۷۴ (اندازه بردار ویژگی ورودی) به ۱۲۸ (بردار ویژگی انتخاب شده) ادامه یافته است که در نهایت بردار ویژگی انتخاب شده به یک‌لایه FC با تابع غیرخطی سافت‌مکس متصل می‌شود.


در این مطالعه همه ابر پارامترهای شبکه پیشنهادی به دقت تنظیم شده‌اند تا بهترین نرخ همگرایی را به دست آورند و در نهایت، تابع خطا کراس آنروپی و بهینه‌ساز آدام با نرخ یادگیری 0.002 انتخاب شده‌اند. روش مرسوم پس انتشار خطا با اندازه دسته ۴ برای آموزش شبکه پیشنهادی، مورد استفاده قرار گرفته است. ابر پارامترهای بهینه انتخاب شده برای مدل پیشنهادی در جدول ۱ نشان داده شده است.

جدول (۱): ابر پارامترهای بهینه استفاده شده در مدل پیشنهادی.

مقدار بهینه	فضای جستجو	پارامتر
Adam	RMSProp, Adam, Adamax, SGD, Adadelata	بهینه‌ساز
Cross-entropy	MSE, Cross-entropy	تابع خطا
۰/۱	۰/۵, ۰/۴, ۰/۳, ۰/۲, ۰/۱, ۰	نرخ لایه حذف تصادفی
۴	۱۰۰, ۶۴, ۳۲, ۱۶, ۱۰, ۸, ۴	اندازه دسته
۰/۰۰۰۲	۰/۰۰۰۳, ۰/۰۰۰۲, ۰/۰۰۰۱, ۰/۰۰۰۱	نرخ یادگیری
Sigmoid	Tanh, Sigmoid, Relu, Linear	تابع فعال‌ساز در لایه FC اول
Tanh	Tanh, Sigmoid, Relu, Linear	تابع فعال‌ساز در لایه FC دوم
Sigmoid	Tanh, Sigmoid, Relu, Linear	تابع فعال‌ساز در لایه FC سوم
Tanh	Tanh, Sigmoid, Relu, Linear	تابع فعال‌ساز در لایه FC چهارم

۳-۴- مجموعه دادگان آموزش و ارزیابی

از کل نمونه‌های جمع‌آوری شده (۷۴۱ نمونه)، ۵۷۳ نمونه برای داده‌های آموزش (۷۷٪)، ۷۹ نمونه برای داده‌های اعتبارسنجی (۱۱٪) و ۸۹ نمونه برای داده‌های آزمون (۱۲٪) استفاده می‌شود. علاوه بر این، تمام نمونه‌های اختصاص داده شده به مجموعه‌های آموزش و ارزیابی به‌طور تصادفی انتخاب می‌شوند. تخصیص نمونه‌ها برای مجموعه داده‌های آموزش، اعتبارسنجی و آزمون در شکل ۳ نشان داده شده است.



شکل (۳): تخصیص دادگان برای مجموعه آموزش، اعتبارسنجی و آزمون.

۵- نتایج و بحث

در این بخش نتایج حاصل شده از شبکه پیشنهادی به صورت کمی در قالب جدول و نمودار ارائه خواهد شد. این بخش شامل ۳ زیر بخش نتایج کمی حاصل شده بر اساس شبکه عمیق پیشنهادی، مقایسه اثربخشی شبکه پیشنهادی با روش‌های اخیر و مقایسه روش پیشنهادی با مطالعات پیشین که در ادامه هر یک از این بخش‌ها به صورت کامل توضیح داده خواهند شد.

۵-۱- نتایج کمی حاصل شده بر اساس شبکه عمیق پیشنهادی

در این مطالعه کلیه نتایج و بررسی‌های مربوط به روش پیشنهادی در نرم‌افزار پایتون با استفاده از کتابخانه‌های متنوعی انجام شده است که مهم‌ترین آن‌ها TensorFlow و NumPy هستند. این بررسی‌ها بر روی یک سیستم رایانه‌ای با مشخصات زیر انجام شده است: پردازنده مرکزی Intel Core i7-6700K، پردازنده گرافیکی GeForce GTX TITAN X 12 GB، رم ۶۴ گیگابایت DDR IV و هارد دیسک ۱ ترابایت SSD. به‌منظور ارزیابی عملکرد روش پیشنهادی، از معیارهای ارزیابی شامل صحت، دقت، نرخ یادآوری استفاده شده است که به‌صورت زیر تعریف می‌شوند [۲۲]:

$$Accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)} \quad (۳)$$

$$Precision = \frac{TP}{(TP + FP)} \quad (۴)$$



$$Recall = \frac{TP}{(TP + FN)} \quad (5)$$

که TP موارد مثبتی است که به درستی مثبت تشخیص داده شده است. همچنین FP، موارد منفی است که به اشتباه مثبت تشخیص داده شده است. TN، موارد منفی است که به درستی منفی تشخیص داده شده است و در نهایت FN، موارد مثبتی است که به اشتباه منفی تشخیص داده شده است.


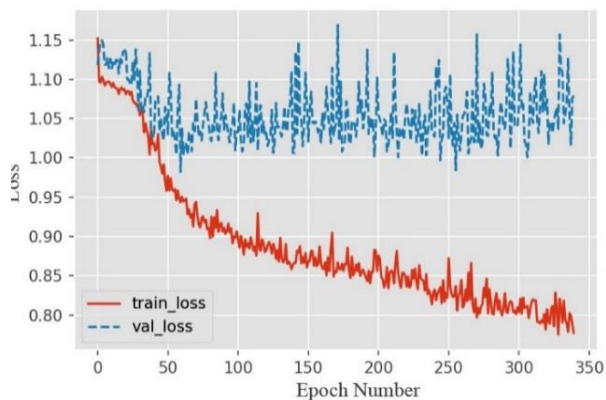
نتایج تجربی مدل پیشنهادی برای ۴ حوزه پیش‌بینی یعنی وضعیت نظارت، وضعیت تسهیلات، تعداد شغل ایجاد شده و مدت فعالیت برای داده‌های آموزش، اعتبارسنجی و آزمون در جدول ۲ ارائه شده است. مطابق با این جدول، صحت، دقت و نرخ یادآوری روش پیشنهادی برای حوزه اول یعنی پیش‌بینی وضعیت نظارت برای داده‌های آزمون به ترتیب ۸۱٪، ۸۶٪ و ۸۱٪ است. همچنین صحت، دقت و نرخ یادآوری روش پیشنهادی برای حوزه دوم یعنی پیش‌بینی وضعیت تسهیلات برای داده‌های آزمون به ترتیب ۵۸٪، ۷۶٪ و ۵۸٪ است. علاوه بر این، صحت، دقت و نرخ یادآوری روش پیشنهادی برای حوزه سوم یعنی پیش‌بینی تعداد شغل ایجاد شده برای داده‌های آزمون به ترتیب ۷۵٪، ۸۹٪ و ۷۵٪ است. همچنین ملاحظه می‌شود که صحت، دقت و نرخ یادآوری روش پیشنهادی برای حوزه چهارم یعنی پیش‌بینی مدت فعالیت برای داده‌های آزمون به ترتیب ۵۶٪، ۹۴٪ و ۵۶٪ است. همان‌طور که ملاحظه می‌گردد صحت مدل پیشنهادی برای حوزه پیش‌بینی وضعیت نظارت از حوزه‌های پیش‌بینی دیگر بیشتر است. همچنین، نمودار صحت و خطا مدل پیشنهادی برای داده‌های آموزش و اعتبارسنجی برای هر ۴ حوزه پیش‌بینی در شکل‌های ۴ تا ۷ ارائه شده است. همان‌طور که ملاحظه می‌گردد، خطای شبکه مدل پیشنهادی برای هر ۴ حوزه، با افزایش تکرار الگوریتم تقریباً کاهش می‌یابد. همچنین مشاهده می‌شود که مدل پیشنهادی پس از ۳۴۰ تکرار برای حوزه‌های پیش‌بینی وضعیت نظارت، پیش‌بینی وضعیت تسهیلات، پیش‌بینی تعداد شغل ایجاد شده و پیش‌بینی مدت فعالیت تقریباً به مقادیر صحت ۸۲٪، ۵۹٪، ۶۷٪ و ۶۳٪ می‌رسد.

جدول (۲): نتایج تجربی مدل پیشنهادی برای ۴ حوزه مختلف پیش‌بینی وضعیت نظارت، پیش‌بینی وضعیت تسهیلات، پیش‌بینی تعداد شغل ایجاد شده و پیش‌بینی مدت فعالیت.

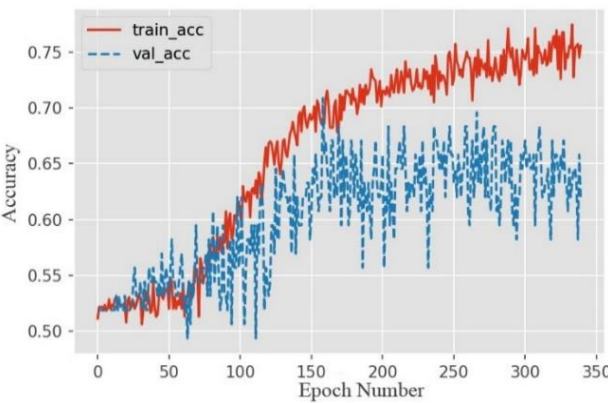

حوزه‌ها	صحت			دقت			نرخ یادآوری		
	آموزش	اعتبارسنجی	آزمون	آموزش	اعتبارسنجی	آزمون	آموزش	اعتبارسنجی	آزمون
پیش‌بینی وضعیت نظارت	۸۱٪	۸۲٪	۸۱٪	۸۷٪	۸۹٪	۸۶٪	۸۱٪	۸۲٪	۸۱٪
پیش‌بینی وضعیت تسهیلات	۵۴٪	۵۹٪	۵۸٪	۶۷٪	۷۰٪	۷۶٪	۵۴٪	۵۹٪	۵۸٪
پیش‌بینی تعداد شغل ایجاد شده	۷۳٪	۶۷٪	۷۵٪	۹۴٪	۸۶٪	۸۹٪	۷۳٪	۶۷٪	۷۵٪
پیش‌بینی مدت فعالیت	۶۴٪	۶۳٪	۵۶٪	۹۶٪	۹۸٪	۹۴٪	۶۴٪	۶۳٪	۵۶٪



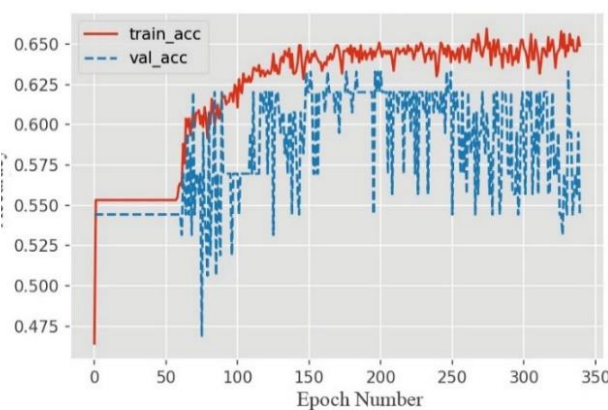

شکل (۴): نمودار صحت و خطا مدل پیشنهادی برای حوزه پیش‌بینی وضعیت نظارت.



شکل (۵): نمودار صحت و خطا مدل پیشنهادی برای حوزه پیش‌بینی تسهیلات.



شکل (۶): نمودار صحت و خطا مدل پیشنهادی برای حوزه پیش‌بینی ایجاد شغل.



شکل (۷): نمودار صحت و خطا مدل پیشنهادی برای حوزه پیش‌بینی مدت زمان فعالیت.

۲-۵- مقایسه اثربخشی شبکه پیشنهادی با روش‌های اخیر

به‌منظور نشان‌دادن عملکرد مدل شبکه عمیق پیشنهادی با مجموعه پایگاه داده جمع‌آوری شده در بخش ۲-۱ به‌عنوان ورودی، صحت ارزیابی حوزه‌های مختلف پیش‌بینی با استفاده از مدل‌های ماشین بولتزمن عمیق^{۴۳}، MLP و SVM نیز به‌دست‌آمده است [۲۳-۲۵]. لایه‌های پنهان و نرخ یادگیری برای DBM و MLP به ترتیب روی ۳ و ۰/۰۰۱ تنظیم شده است. همچنین، تابع خطای کراس آن‌تروپی^{۴۴} برای این دو شبکه بکار گرفته شد. علاوه بر این، تابع پایه شعاعی گوسین^{۴۵} به‌عنوان تابع کرنل ماشین بردار پشتیبان و از روش جستجوی شبکه برای بهینه‌سازی پارامترهای کرنل استفاده شده است. صحت ارزیابی مدل پیشنهادی با مدل‌های مورد مقایسه، در حوزه‌های مختلف پیش‌بینی در جدول ۳ ارائه شده است. مقایسه عملکرد این ۴ مدل نشان می‌دهد که یادگیری ویژگی از داده‌ها با مدل شبکه عمیق پیشنهادی، نتایج بهتری نسبت به مدل‌های مورد مقایسه برای حوزه‌های مختلف پیش‌بینی ارائه می‌دهد. این نتایج کاملاً به معنای منحصر‌به‌فرد مدل شبکه عمیق پیشنهادی مربوط می‌شود که می‌تواند به‌صورت خودکار ویژگی‌های مفید را از داده‌ها استخراج کند.

جدول (۳): صحت ارزیابی مدل شبکه عمیق پیشنهادی برای حوزه‌های مختلف پیش‌بینی در مقایسه با مدل ماشین بردار پشتیبان.

مدل‌ها	پیش‌بینی وضعیت نظارت	پیش‌بینی وضعیت تسهیلات	پیش‌بینی تعداد شغل ایجادشده	پیش‌بینی مدت فعالیت
ماشین بولتزمن عمیق	۷۴٪	۴۵٪	۷۲٪	۵۱٪
شبکه عصبی	۶۸٪	۴۶٪	۶۴٪	۴۳٪
ماشین بردار پشتیبان	۷۲٪	۴۶٪	۶۸٪	۴۵٪
شبکه عمیق پیشنهادی	۸۱٪	۵۸٪	۷۵٪	۵۶٪

۳-۵- مقایسه روش پیشنهادی با مطالعات پیشین

صحت ارزیابی روش‌های مختلف برای پیش‌بینی حوزه‌های کاری مختلف در جدول ۴ ارائه شده است که نتایج مدل شبکه عمیق پیشنهادی، در جدول ۴ به‌صورت برجسته مشخص شده است. این مقایسه‌ها بر پایه مجموعه داده‌های استاندارد، برای پیش‌بینی حوزه‌های کاری مختلف مانند پیش‌بینی ورشکستگی، امتیازدهی اعتباری، ارزیابی ریسک و ارزیابی کسب‌وکار انجام شده است. لازم به ذکر است که در این جدول در هر بررسی نام پایگاه داده، تعداد نمونه‌ها، تعداد ویژگی‌ها، حوزه کاری و روش مورد استفاده نیز ارائه شده است. همان‌طور که از جدول ۴ ملاحظه می‌گردد، در بیشتر بررسی‌های انجام شده، مقادیر صحت ارائه شده، نشان‌دهنده عملکرد بهتر مدل شبکه عمیق پیشنهادی در مقایسه با سایر روش‌ها است. به‌منظور دستیابی به نتایج بهتری از مدل پیشنهادی، ابر پارامترهای آن با توجه به داده‌های مختلف تنظیم می‌شود. لازم به ذکر است که شبکه‌های عمیق نیازمند تعداد نمونه‌ها و ویژگی‌های اولیه نسبتاً زیادی هستند و معمولاً افزایش این دو پارامتر باعث افزایش صحت این

^{۴۳} Deep Boltzmann Machine (DBM)

^{۴۴} Cross Entropy

^{۴۵} Radial basis function (RBF)

شبکه‌ها می‌گردد؛ بنابراین، همان‌طور که از جدول ۴ ملاحظه می‌گردد در برخی از بررسی‌های انجام‌شده به دلیل کمبود تعداد نمونه‌ها و تعداد ویژگی‌های اولیه، صحت مدل پیشنهادی کمتر از روش‌های دیگر شده است.

جدول (۴): صحت ارزیابی روش‌های مختلف برای پیش‌بینی حوزه‌های کاری مختلف.

صحت آزمون	روش	حوزه کاری	تعداد ویژگی‌ها	تعداد نمونه‌ها (رکوردها)	پایگاه داده
۹۱/۸۳٪	زوریک و همکاران [۱]	Bankruptcy	۲۰	۱۰۰۰	FinancialR of Slovak Companies
۹۱/۱۲٪	مدل پیشنهادی				
۹۹/۸٪	شومو و همکاران [۱۷]	Credit Risk Assessment	۳۲	۳۸۶۶۱	USA Lending Club
۹۷/۵۶٪	مدل پیشنهادی				
۷۲٪	پتروپولوس و همکاران [۱۱]	Credit Risk Analysis	۶۵	۲۰۰۰۰	Greece banking System
۹۹/۳۳٪	مدل پیشنهادی				
۸۸/۲۸٪	شیا و همکاران [۱۴]	Credit Scoring	۲۴	۱۰۰۰	German Credit
۹۳/۱۳٪	مدل پیشنهادی				
۹۲٪	بائو و همکاران [۹]	Credit Risk Assessment	۸۱	۲۳۴۳۵	Chinese P2P Credit
۹۳/۴۴٪	مدل پیشنهادی				
۸۸/۶٪	داحیه و همکاران [۱۰]	Credit Risk Evaluation	۲۴	۱۰۰۰	German Credit
۹۳/۷۳٪	مدل پیشنهادی				
۹۵/۰۸٪	ابلان و همکاران [۱۲]	Credit Scoring	۲۷	۱۰۰۰	Iranian
۹۳/۸۷٪	مدل پیشنهادی				
۸۶/۹٪	بکه و همکاران [۱۳]	Credit Scoring	۱۴	۶۹۰	Australian Credit (AC)
۸۸/۴۲٪	مدل پیشنهادی				
۸۴/۶۵٪	لوپس و همکاران [۷]	Credit Return Probability Estimation	۳۲	۲۲۷۶۴	Brazilian National Financial System
۹۳/۱۳٪	مدل پیشنهادی				
۷۴/۶۸٪	ها و همکاران [۲۶]	Credit Scoring	۲۰	۱۰۰۰	German Credit
۹۰/۵۶٪	مدل پیشنهادی				
۷۷/۷۲٪	علاج و دیگران [۲۷]	Credit Scoring	۲۰	۱۰۰۰	German Credit
۹۰/۴۳٪	مدل پیشنهادی				
۹۶/۵۰٪	خانابایی و همکاران [۸]	Credit Scoring	۱۷	۵۱۷۳	Mellat Bank of Iran
۹۵/۱۷٪	مدل پیشنهادی				

۶- نتیجه‌گیری

با توجه به پیچیدگی انتخاب درست متقاضیان تسهیلات در سیستم‌های بانکی، هدف این مطالعه ارائه یک روش جدید برای انتخاب درست متقاضیان تسهیلات در ۴ حوزه پیش‌بینی یعنی پیش‌بینی ورشکستگی، امتیازدهی اعتباری، ارزیابی ریسک و ارزیابی کسب‌وکار ایجاد شده است. در این مطالعه یک مدل شبکه عصبی عمیق برای استخراج ویژگی‌ها از داده‌های خام ورودی،

طراحی و توسعه یافته و یک مجموعه داده جامع بر پایه استانداردهای موجود طراحی شده است. استانداردسازی و یکسانسازی داده‌ها برای ایجاد پایگاه داده‌های مربوط به اعتبارسنجی مشتریان و ارزیابی کسب‌وکار، افزایش میزان کارآفرینی، هدفمندسازی اعطای تسهیلات اشتغال، افزایش ضریب اطمینان از ایجاد کسب‌وکار، جلوگیری از هدایت نادرست منابع به عرصه‌هایی غیر از تولید و به تبع آن جلوگیری از ایجاد تورم از مزایای روش پیشنهادی در این مطالعه می‌باشد.

مطالعه حاضر نشان داد که روش پیشنهادی می‌تواند ویژگی‌ها را از روی داده‌های خام ورودی بیاموزد و به صحت قابل قبولی برای انتخاب درست متقاضیان تسهیلات دست یابد. مدل پیشنهادی به همراه مجموعه داده جمع‌آوری شده، در ۴ حوزه پیش‌بینی مورد بررسی قرار گرفت. نتایج نشان داد که مدل پیشنهادی در انتخاب درست متقاضیان تسهیلات برای مجموعه داده بیان شده، نتایج امیدوارکننده‌ای ارائه می‌دهد. علاوه بر این، صحت مدل پیشنهادی برای ۴ حوزه پیش‌بینی با روش هوشمند SVM مقایسه شد. نتایج نشان داد که روش پیشنهادی قادر به یادگیری ویژگی‌ها و به‌دست‌آوردن نتایج قانع‌کننده‌تری برای حوزه‌های مختلف پیش‌بینی در مقایسه با SVM می‌باشد. همچنین، صحت روش‌های مختلف برای چندین مجموعه داده جامع برای پیش‌بینی حوزه‌های کاری مختلف با مدل پیشنهادی مقایسه شد. صحت به‌دست‌آمده برای حوزه‌های پیش‌بینی وضعیت نظارت، پیش‌بینی وضعیت تسهیلات، پیش‌بینی تعداد شغل ایجاد شده و پیش‌بینی مدت فعالیت به ترتیب ۸۱، ۵۸، ۷۵ و ۵۶ درصد است که در مقایسه با سایر روش‌ها و مطالعات اخیر امیدوارکننده بوده و اثربخشی بیشتری دارد.

با توجه به نتایج روش پیشنهادی در ۴ حوزه پیش‌بینی که به‌صورت عملیاتی در چندین شعبه از صندوق‌های کارآفرینی پیاده‌سازی شده است، می‌توان بیان کرد که روش پیشنهادی برای انتخاب درست متقاضیان تسهیلات بسیار رضایت‌بخش و مناسب است و می‌تواند با ورود به حوزه کاربردی، دستیار خوبی برای متخصصان این حوزه باشد. علاوه بر این، می‌توان با توسعه پایگاه داده از دو طریق افزودن اطلاعات وام‌گیرندگان بیشتر و از سوی دیگر اضافه کردن ویژگی‌های اولیه همانند وضعیت مالکیت محل سکونت وام‌گیرنده، شهری یا روستایی بودن محل سکونت وام‌گیرنده، سابقه کار و سطح تحصیلات کارشناس بررسی‌کننده تسهیلات، نوع ضمانت اخذ شده که امکان دسترسی به آن‌ها و گردآوری آن‌ها در پرونده تسهیلاتی وام‌گیرندگان وجود دارد، علاوه بر افزایش صحت پیش‌بینی‌های انجام شده در ۴ حوزه بیان شده، میزان تأثیرگذاری ویژگی‌های اولیه را در تعیین احتمالات ارزیابی کرد.

۷- منابع

- [1] M. Zoričák, P. Gnyp, P. Drotár, and V. Gazda, "Bankruptcy prediction for small-and medium-sized companies using severely imbalanced datasets," *Economic Modelling*, vol. 84, pp. 165-176, 2020.
- [2] M. Soui, S. Smiti, M. W. Mkaouer, and R. Ejbali, "Bankruptcy prediction using stacked auto-encoders," *Applied Artificial Intelligence*, vol. 34, no. 1, pp. 80-100, 2020.
- [3] D. M. Obare, G. G. Njoroge, and M. M. Muraya, "Analysis of Individual Loan Defaults Using Logit under Supervised Machine Learning Approach," *Asian Journal of Probability and Statistics*, pp. 1-12, 2019.
- [4] L. Motiwalla and M. Wahab, "Predictable variation and profitable trading of US equities: a trading simulation using neural networks," *Computers & Operations Research*, vol. 27, no. 11-12, pp. 1111-1129, 2000.
- [5] N. Metawa, M. Elhoseny, M. K. Hassan, and A. E. Hassanien, "Loan portfolio optimization using genetic algorithm: a case of credit constraints," in *2016 12th international computer engineering conference (ICENCO)*, 2016: IEEE, pp. 59-64.
- [6] Metawa, N., M.K. Hassan, and M.J.E.S.w.A. Elhoseny, Genetic algorithm based model for optimizing bank lending decisions. 2017. 80: p. 75-82.

- [7] N. Metawa, M. K. Hassan, and M. Elhoseny, "Genetic algorithm based model for optimizing bank lending decisions," *Expert Systems with Applications*, vol. 80, pp. 75-82, 2017.
- [8] M. Khanbabaee, "The use of genetic algorithm, clustering and feature selection techniques in construction of decision tree models for credit scoring," *International Journal of Managing Information Technology (IJMIT)* Vol, vol. 5, 2013.
- [9] W. Bao, N. Lianju, and K. Yue, "Integration of unsupervised and supervised machine learning algorithms for credit risk assessment," *Expert Systems with Applications*, vol. 128, pp. 301-315, 2019.
- [10] S. Dahiya, S. Handa, and N. Singh, "A feature selection enabled hybrid-bagging algorithm for credit risk evaluation," *Expert Systems*, vol. 34, no. 6, p. e12217, 2017.
- [11] A. Petropoulos, V. Siakoulis, E. Stavroulakis, and A. Klamargias, "A robust machine learning approach for credit risk analysis of large loan level datasets using deep learning and extreme gradient boosting," *IFC Bulletins chapters*, vol. 49, 2019.
- [12] J. Abellán and J. G. Castellano, "A comparative study on base classifiers in ensemble methods for credit scoring," *Expert Systems with Applications*, vol. 73, pp. 1-10, 2017.
- [13] A. Bequé and S. Lessmann, "Extreme learning machines for credit scoring: An empirical evaluation," *Expert Systems with Applications*, vol. 86, pp. 42-53, 2017.
- [14] Y. Xia, C. Liu, B. Da, and F. Xie, "A novel heterogeneous ensemble credit scoring model based on bstacking approach," *Expert Systems with Applications*, vol. 93, pp. 182-199, 2018.
- [15] Luo, C., D. Wu, and D.J.E.A.o.A.I. Wu, "A deep learning approach for credit scoring using credit default swaps." 2017. 65: p. 465-470.
- [16] C. Luo, D. Wu, and D. Wu, "A deep learning approach for credit scoring using credit default swaps," *Engineering Applications of Artificial Intelligence*, vol. 65, pp. 465-470, 2017.
- [17] S. Z. H. Shoumo, M. I. M. Dhruva, S. Hossain, N. H. Ghani, H. Arif, and S. Islam, "Application of Machine Learning in Credit Risk Assessment: A Prelude to Smart Banking," in *TENCON 2019-2019 IEEE Region 10 Conference (TENCON)*, 2019: IEEE, pp. 2023-2028.
- [18] Gribonval, R., Kutyniok, G., Nielsen, M. and Voigtlaender, F., 2021. Approximation spaces of deep neural networks. *Constructive Approximation*, pp.1-109.
- [19] R. Gribonval, G. Kutyniok, M. Nielsen, and F. Voigtlaender, "Approximation spaces of deep neural networks," *Constructive Approximation*, pp. 1-109, 2021.
- [20] P. Benz, C. Zhang, A. Karjauv, and I. S. Kweon, "Revisiting batch normalization for improving corruption robustness," in *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 2021, pp. 494-503.
- [21] C. Han, Y. Lei, Y. Xie, D. Zhou, and M. Gong, "Learning smooth representations with generalized softmax for unsupervised domain adaptation," *Information Sciences*, vol. 544, pp. 415-426, 2021.
- [22] D. M. Powers, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation," *arXiv preprint arXiv:2010.16061*, 2020.
- [23] S. Sheykhivand, Z. Mousavi, T. Y. Rezaii, and A. Farzamia, "Recognizing Emotions Evoked by Music Using CNN-LSTM Networks on EEG Signals," *IEEE Access*, vol. 8, pp. 139332-139345, 2020.
- [24] S. Sheykhivand, T. Y. Rezaii, Z. Mousavi, and S. Meshgini, "Automatic Stage Scoring of Single-Channel Sleep EEG using Discrete Wavelet Transform and a Hybrid Model of Simulated Annealing Algorithm and Neural Network," *Iranian Journal of Biomedical Engineering*, vol. 11, no. 4, pp. 313-325, 2018.
- [25] Z. Mousavi, S. Varahram, M. M. Etefagh, M. H. Sadeghi, and S. N. Razavi, "Deep neural networks-based damage detection using vibration signals of finite element model and real intact state: An evaluation via a lab-scale offshore jacket structure," *Structural Health Monitoring*, p. 1475921720932614, 2020.
- [26] V.-S. Ha and H.-N. Nguyen, "Credit scoring with a feature selection approach based deep learning," in *MATEC Web of Conferences*, 2016, vol. 54: EDP Sciences, p. 05004.
- [27] M. Ala'raj and M. F. Abbod, "Classifiers consensus system approach for credit scoring," *Knowledge-Based Systems*, vol. 104, pp. 89-105, 2016.