

## Improvement payment loan concerning financial discipline and maximum gain in uncertainly

 <http://orcid.org/0000-0002-7020-7482><sup>۱</sup>

 <http://orcid.org/0000-0003-4327-8320><sup>۲</sup>

 <http://orcid.org/0000-0002-4420-3093><sup>۳</sup>

 <http://orcid.org/0000-0001-7048-9064><sup>۴</sup>

۱. Roya Cheshmikhani

۲. Mohammad Ali Afshar Kazemi

۳. Abbas Toluie Ashlaghi

۴. Ezatollah Asgharizadeh

---

### Article Info

#### Article type:

Research Article

#### Keywords:

Facilities,  
Data Mining,  
Deep learning,  
Clustering,  
CNN,  
CNN-LSTM.

---

### ABSTRACT

Granting facilities is an important part of every bank's operations. This part of banking activities is economically important. With its operations, banks can provide the transfer of resources from those that have directly invested to those who need money, this repayment makes another people use these resources. Failure to repay facilities on time will cause the bank's resources to stagnate and in the long will cause the country's economic recession. It is important to monitor the correct allocation of resources because if bank resources are used and unfounded payments are made, the banks will not be able to pay the depositors and will become bankrupt. By examining the researches in the field of banking, it was found that most of the researches have focused on the optimal combination of the investment portfolio in the capital market, and less researchers have paid attention to the discussion of the optimal combination in the money market. Most of the researches that used operational and statistical research methods were related to industrial issues, and less in financial issues and operational research discussions were used. In the optimal portfolio of the combination of facilities or investments, mostly the genetic algorithm has been used and less than other fuzzy methods have been used in the conditions of uncertainty. Therefore, in this research, the improvement of facility payment modeling has been addressed by using convolutional neural networks and CNN-LSTM modeling.

---



## بهبود پرداخت تسهیلات با در نظر گرفتن انضباط مالی و حداکثر سودآوری در شرایط عدم اطمینان

رویا چشمی خانی<sup>۱</sup>، محمد علی افشار کاظمی<sup>۲</sup>، عباس طلوعی اشلقی<sup>۳</sup>، عزت الله اصغری زاده<sup>۴</sup>

### چکیده

اعطای تسهیلات، بخش مهمی از عملیات هر بانک را تشکیل می دهد و این قسمت از فعالیتهای بانکی از لحاظ اقتصادی حائز اهمیت است. بانک ها با عملیات اعتباری خود موجبات انتقال منابع را از اشخاصی که مستقیماً در بانک سرمایه گذاری کرده اند به کسانی که به پول نیاز دارند فراهم می کنند و این اشخاص با بازپرداخت اقساط خود باعث می شوند گروهی دیگر از مردم بتوانند از این منابع استفاده کنند. عدم بازپرداخت به موقع تسهیلات باعث راکد شدن منابع بانک و در بلندمدت باعث رکود اقتصادی کشور می شود. نظارت بر نحوه ی صحیح تخصیص منابع و بهداشت اعتباری امری بسیار مهم می باشد زیرا در صورت تخصیص نامطلوب منابع بانک و پرداخت بی اصول تسهیلات، بانک ها توان بازپرداخت سپرده های سپرده گذاران را نداشته و با ورشکستگی مواجه خواهند گردید. با بررسی پژوهش های سالهای اخیر در زمینه بانکداری مشخص گردید اکثر پژوهش ها ترکیب بهینه ی سبد سرمایه گذاری بیشتر در بازار سرمایه پرداخته و کمتر پژوهشگری به بحث و بررسی ترکیب بهینه در بازار پولی توجه نموده است. بیشتر پژوهش هایی که از روشهای تحقیق در عملیات و آماری استفاده گردیده در خصوص مسائل صنعتی بوده و کمتر در مسائل مالی از بحث های تحقیق در عملیات استفاده شده است. در پرتفوی بهینه ترکیب تسهیلات یا سرمایه گذاری ها اکثراً از الگوریتم ژنتیک بهره مند شده و کمتر از دیگر روش های فازی در شرایط عدم اطمینان استفاده شده است. بنابراین در این پژوهش به مدلسازی بهبود پرداخت تسهیلات با استفاده از مدلسازی شبکه های عصبی کانولوشنی<sup>۵</sup> و CNN-LSTM<sup>۶</sup>، پرداخته شده است.

**کلیدواژه ها:** تسهیلات، داده کاوی، خوشه بندی، یادگیری عمیق، شبکه عصبی CNN، شبکه عصبی CNN-LSTM

<sup>۱</sup> - دانشجوی دکتری رشته مدیریت صنعتی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران

<sup>۲</sup> - دانشیار رشته مدیریت صنعتی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران

<sup>۳</sup> - استاد تمام رشته مدیریت صنعتی، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران، ایران

<sup>۴</sup> - دانشیار رشته مدیریت صنعتی، دانشگاه تهران، تهران، ایران

<sup>۵</sup> - Convolutional neural network

<sup>۶</sup> - Long-Short Term Memory

## مقدمه

به دلیل گسترش مناسب نظام پولی و مالی، عملاً بانک‌ها و شبکه‌ی بانکی به عنوان مهمترین نهاد مالی وظیفه جمع‌آوری و تخصیص منابع اقتصاد را بر عهده گرفته است. بازار سرمایه یکی از ارکان مهم اقتصاد در جامعه است که از آن به عنوان دماسنج اقتصاد یاد می‌شود. بازار سرمایه پلی است که پس انداز واحدهای اقتصادی دارای مازاد مانند شرکتها و دولتها را به واحدهای سرمایه‌گذاری که بدان نیازمندند انتقال می‌دهد. در مورد نهادهای موجود در بازار پول نیز این مورد صادق است. بانک‌های تجاری و مؤسسات مالی و اعتباری از یک طرف وجوه را از مردم به عنوان سپرده می‌گیرند و در قبال آن به آنها پاداش پولشان (بهره) می‌دهند. از طرف دیگر این سپرده‌ها توسط این نهادها به دست افرادی که به این وجوه نیاز دارند انتقال خواهد یافت. مکانیزم این انتقال همان فرایند اعطای تسهیلات است که ورودی آن تقاضای مشتریان از بانک‌ها و مؤسسات مالی و اعتباری بوده و خروجی آن اعطای وجوه به آنها است و در این میان باید مدیریت پرتفوی اعتبارات صورت گیرد. در تعیین سیاستهای مربوط به اعطای تسهیلات، مؤسسات مالی باید محورهای اصلی برنامه‌ی اعطای تسهیلات، نحوه تخصیص تسهیلات اعتباری و نیز شیوه مدیریت مجموعه‌ی تسهیلات اعطایی را مورد توجه قرار دهند و پرداخت تسهیلات به بخش‌های مختلف (صنعتی، خدماتی، کشاورزی) بر اساس تأثیرگذاری بر توسعه کسب و کار خرد مورد نظر قرار می‌گیرد. بانک‌ها در اداره کشورها نقش تعیین‌کننده و از مهمترین ابزار رشد و توسعه کشور محسوب می‌شوند. بانک‌های تجاری ایران همواره از مهمترین نهادهای فعال در بازار پول و سرمایه به‌شمار می‌روند و با توجه به ساختار اقتصادی کشور و دلایلی چون عدم توسعه‌ی بازارهای سرمایه و سایر شبکه‌های غیربانکی، تأمین مالی بخش‌های اقتصادی کشور را برعهده دارند. امروزه مهم‌ترین دغدغه‌ی بانک‌ها به منظور افزایش سودآوری، پرداخت اصولی تسهیلات به افرادی می‌باشد که ریسک کمتری جهت بازپرداخت اقساط داشته باشند که به ترتیب ریسک اعتباری بانک کاهش یابد و به تبع آن با ریسک نقدینگی و ریسک شهرت کمتری مواجه گردند (Armantier & others, 2015). اکنون بانک‌ها با حجم زیادی از مطالبات غیرجاری مواجه می‌باشند که عمده‌ترین علت آنها پرداخت غیراصولی تسهیلات و عدم رعایت بهداشت اعتباری می‌باشد (Zangeneh, Mohammadi, 2016). این امر باعث بلوکه شدن قسمت عظیمی از پول بانک‌ها و سپرده سپرده‌گذاران دیگر گردیده و باعث افزایش هزینه و کاهش درآمدهای مشاع بانکها گردیده است (Khosroyani, 2022). وجود سیستم مناسب اعطای تسهیلات و ارزیابی فرصت‌های سرمایه‌گذاری و وام‌دهی و اطمینان از وجود رویه‌های مناسب در پذیرش و اعطای تسهیلات موجب جلب اعتماد و کسب شهرت برای مؤسسات مذکور خواهد شد (عسگرزاده, 1386). با طراحی و اجرای تکنیک‌های بهینه‌سازی، مدیریت امور نهاد مالی می‌تواند با توجه به سیاستهای کلان اعتباری و برنامه‌های اعتباری استراتژیک نهاد مالی و در نظر داشتن اولویت‌های تسهیلات از منظر ریسک و بازده به تصمیمات مناسب دست یابد.

در این پژوهش سعی گردیده مدلی جهت بهینه‌سازی پرداخت تسهیلات ارائه گردد بطوریکه با استفاده از این مدل موسسه اعتباری قادر به اعتبارسنجی صحیح و سریع مشتریان درخواست‌کننده تسهیلات بوده و با شناسایی مشتریان اعتباری میزان ریسک و سودآوری مشتری برای مؤسسه قبل از پرداخت تسهیلات مشخص می‌گردد و بانکها و مؤسسات مالی اطمینان می‌یابند که با پرداخت تسهیلات سپرده‌های سپرده‌گذاران دیگر سوخت نمی‌گردد و بانک‌ها متضرر نمی‌شوند در این پژوهش ابتدا ادبیات نظری پژوهش مورد بررسی و تحلیل قرار گرفته و هم‌زمان با آن، تحلیل جامع مرتبط با موضوع در نظام بانکی نیز بررسی شد سپس با استناد به نتایج به دست آمده از ادبیات نظری و تحلیل‌های نظام بانکی و با توجه به یافته‌های موردانتظار و با استفاده از ابزارهای شبیه‌سازی و داده‌کاوی اقدام به مدل‌سازی برای خوشه‌بندی مشتریان یکی از بانک‌های خصوصی گردید و سپس با استفاده از یادگیری عمیق و تلفیق روش‌های دسته‌بندی فازی از جمله شبکه‌های عصبی کانولوشنی و شبکه عصبی CNN-LSTM به پیش‌بینی رفتار مشتریان در حوزه پرداخت تسهیلات در شبکه بانکی کشور پرداخته شد.

یک شبکه عصبی کانولوشن شامل یک ورودی و یک لایه خروجی و همچنین چندین لایه پنهان است. شبکه عصبی کانولوشن نشان می‌دهد که شبکه از یک عملیات ریاضی به نام کانولوشن بهره می‌برد کانولوشن نوعی تخصصی از عملیات خطی است (Khalila & others, 2021). شبکه‌های

بهبود پرداخت تسهیلات با در نظر گرفتن انضباط مالی و حداکثر سودآوری در شرایط عدم اطمینان

کانولوشنال مانند شبکه‌های عصبی، ساده هستند که حداقل در یکی از لایه‌های خود از کانولوشن به جای ضرب ماتریس عمومی بهره می‌برند. همچنین معماری CNN-LSTM شامل CNN برای استخراج ویژگی و LSTM برای یادگیری وابستگی‌های دراز مدت است (دامی، خیری، ۱۳۹۷). این مدل می‌تواند توانایی‌های شبکه CNN و LSTM را مهار کند و نتایج بهتری با دقت ۸۵٪ به دست آورد.

## ۱. مروریادبیات

مفهوم تشکیل سبد تسهیلات و تشکیل پرتفوی دارایی‌ها از دهه ۱۹۵۰ توسط مارکوینز مطرح شده اما از دهه ۱۹۸۰ کاربرد این مفهوم برای دارایی‌های اعتباری توسعه یافت و به دنبال آن در دهه ۱۹۹۰ مدل‌های سبد تسهیلات اعتباری معرفی شدند. نظریه مدرن پرتفولیو بر اساس دو فرض بنا نهاده شده است، فرض اول اینکه سرمایه‌گذاران ریسک‌گریز هستند و فرض دوم این است که بازده اوراق بهادار دارای توزیع مشترک نرمال هستند، نتیجه این مفروضات آن است که بازده موردانتظار و انحراف استاندارد به طور کامل توزیع بازده اوراق بهادار را توصیف می‌کند. در مورد سهام، علاقمندی به بازده و در مورد تسهیلات و دارایی‌های اعتباری علاقمندی به شناسایی زیان‌های مورد انتظار تسهیلات وجود دارد. عمده تحقیقات موجود بر روی بهینه‌سازی سبدهای سرمایه‌گذاری بر مبنای الگوها و روش‌های مختلف انجام گرفته که در غالب این مدل‌ها بهینه‌سازی بر مبنای معیارهای مبتنی بر میانگین، واریانس انجام گرفته است (راعی، فرهادی، شیروانی، ۱۳۹۰). در اکثر پژوهش‌ها به بررسی غیر خطی تصمیمات سرمایه‌گذاران پرداخته شده است.

## ۲. پیشینه پژوهش

خلاصه‌ای از تحقیقات پیشین در خصوص ترکیب بهینه تسهیلات بشرح جدول ذیل می‌باشد:

جدول (۱) خلاصه تحقیقات پیشین

نام محقق	سال تحقیق	روش تحقیق	ورودی‌ها	خروجیها
عسگر زاده	۱۳۸۵	فنون تحقیق در عملیات	تسهیلات	سود
ابزازی، کتابی و عباسی	۱۳۸۴	تحقیق در عملیات	سرمایه‌گذاری	ریسک
خالدزاده و امیری	۱۳۸۹	الگوریتم ژنتیک	سرمایه‌گذاری در بورس	ریسک
عبدالعلی زاده شهیر و عشقی	۱۳۹۰	الگوریتم ژنتیک	سرمایه‌گذاری در بورس	ریسک
نوید، نجومی و میرزاده	۱۳۹۳	الگوریتم ژنتیک	سرمایه‌گذاری در بورس	ریسک
استیفن لی و پیتر بارنه	۱۹۹۴	شبه‌سازی	سهام	سود و ریسک
او، کیم و مین	۲۰۰۵	الگوریتم ژنتیک	سرمایه‌گذاری در صندوق‌های مشاع	سود
چانگ، یانگ	۲۰۰۹	روشهای آماری	سرمایه‌گذاری	سود و ریسک
تاتیا هوبنو و	۲۰۱۴	شبه‌سازی	تسهیلات	ریسک و بازده
یاسمین بشیر مالیم	۲۰۱۷	شبه‌سازی	تسهیلات	سود و ریسک

در جدول شماره ۲ محدودیت‌ها و قابلیت‌های (نقاط قوت و ضعف) هر یک از روش‌های مورد مطالعه در حوزه‌های کلان در ادبیات موضوع در مقایسه با روش تحقیق این پژوهش به صورت مختصر ارائه گردیده است:

جدول (۲) نقاط قوت و ضعف روش‌های بررسی شده

روش	نقاط ضعف	نقاط قوت
سیستم‌های خبره	عدم ثبات، درونی و ذهنی بودن، پرهزینه و زمان بر بودن	می‌توانند نتایج خود را توضیح دهند، یعنی قدم به قدم یا به طور متوالی منطبق بیاورند.
روش‌های سنتی آماری	به دلیل الزامات محدودکننده، کاربردهای محدودی دارند.	در محدوده داده‌های کوچک یا بزرگ، جواب‌های قابل قبول ارائه می‌دهند.
روش‌های داده‌کاوی	با وجود اینکه به آشکارسازی الگوها و روابط کمک می‌کند اما اطلاعاتی را درباره‌ی ارزش یا میزان اهمیت آنها به دست نمی‌دهد. با وجود توانایی شناسایی روابط بین رفتارها و یا متغیرها لزوماً قادر به کشف روابط علت و معلولی نیست. موفقیت داده‌کاوی در گرو بهره‌گیری از کارشناسان فنی و تحلیل‌گران کار آزموده‌ای است که از توانایی کافی برخوردار هستند.	به گونه‌ای گسترش یافته‌اند که به سادگی می‌توان آنها را با ابزارهای نرم‌افزاری و... امروزی تطبیق داده و از اطلاعات جمع‌آوری شده بهترین بهره را برد.
مدل‌های رگرسیونی	نیازمند ورودی‌ها بصورت مقادیر عددی هستند متغیرهای دسته‌بندی شده باید بصورت متغیرهای عددی تبدیل گردند. هم خطی بین متغیرهای مستقل ورودی، اثر منفی روی نتایج می‌گذارد.	بسیار پرکاربرد در تدوین نمره دهی اعتباری مشتریان، پی‌نمایی به فرضیات محدودکننده آماری، در رابطه با متغیرها می‌توان اهمیت نسبی متغیرهای مربوطه را به دست آورد.
تحلیل ممیزی خطی	نیازمند ورودی‌ها بصورت مقادیر عددی، فرض توزیع نرمال برای متغیرها و نیز برابر بودن ماتریس کوواریانس برای تمامی گروه‌ها که در واقع مهمترین نقد وارده بر این روش می‌باشد.	اگر به دنبال روشی باشیم که ترکیب خطی متغیرها را به گونه‌ای به دست دهد که هم زمان معیار تفکیک خاصی حداکثر شود، این روش پرکاربرد است. در برخی موارد دیده شده نقض شدن فرض نرمال در داده‌ها، مانع کارآمدی آن نشده است.

<p>از برنامه‌ریزی خطی حتی هنگامی که دو گروه به صورت خطی قابل جداسازی نیستند با استفاده از حداقل کردن حداکثر خطاها یا جمع خطاهای مطلق، می‌توان استفاده کرد.</p>	<p>به منظور استفاده از این مدل باید یک حد مرزی تعیین کرد که با توجه به آن متقاضیان اعتباری به گروه‌های مختلف تقسیم شوند که این ممکن است به راحتی قابل حصول نباشد.</p>	<p>برنامه‌ریزی خطی</p>
<p>می‌توان با فرضیاتی ساده، دانش را از داده‌ها استخراج کرد. خروجی می‌تواند هم امتیاز پیوسته و هم عضویت در کلاس‌ها باشد (Huang, 2018). ماهیت غیرپارامتریک این روش، مدل‌سازی موارد بی‌قاعده در تابع ریسک در فضای مشخصات مشتریان را ممکن می‌سازد. این فرآیند کاملاً شهودی بوده و به راحتی قابل توضیح به مدیران است، زیرا به لحاظ مفاهیم و به کارگیری ساده می‌باشد. قابل به کارگیری بصورت پویا و گام به گام بوده و با ورود موارد جدید، می‌تواند خودش را روزآمد کند.</p>	<p>عملکرد این روش در مقایسه با سایر مدل‌های مرسوم، وابسته به تعداد وام‌های بد (تعداد نکول) در داده‌هاست. معمولاً هم احتمال بودن وام‌های خوب و بد در مجموعه یادگیری، کارآیی این مدل را بهتر می‌کند؛ که عملاً این گونه نیست.</p>	<p>یادگیری بر مبنای مورد</p>
<p>می‌تواند با فرضیاتی ساده، دانش را از دل داده‌ها استخراج کنند خروجی می‌تواند هم به صورت امتیازات پیوسته و هم به صورت عضویت در کلاس‌ها باشد. روی ورودی‌ها و خروجی‌های غیرخطی هم کار می‌کند که در تحلیل‌های مالی که اغلب متغیرها غیرخطی هستند بسیار مفید است. مناسب برای شرایطی که ساختار مسئله غیرشفاف است و باید نوعی روندیابی یا بازشناسی الگو صورت بگیرد و داده‌های موجود ناقص و تحریف شده‌اند که مدیران مؤسسات مالی و نهادهای سرمایه‌گذاری عملاً با بسیاری از این</p>	<p>نیازمند ورودی‌ها بصورت مقادیر عددی متغیرهای ورودی ممکن است مقیاس‌های متفاوتی داشته باشند و اثر آنها بر خروجی، به طور نامساوی سنجیده شود، که در این صورت مدل دچار خطا می‌شود. بنابراین مقادیر هر ورودی نیازمند هم مقیاس شدن می‌باشند (اعدادی بین صفر و یک). مشکل بودن فرآیند آموزش در آن که تا حد زیادی کاربرد آن را محدود کرده است. نمی‌تواند نتایج خود را توضیح دهند، یعنی قدم به قدم یا به طور متوالی منطبق بیاورند.</p>	<p>شبکه‌های عصبی</p>

مسائل مواجهه اند.		
<p>سادگی روش و پرکاربرد بودن آن به جهت مقایسه و اعتبارسنجی سایر روش‌های مورد استفاده کم هزینه و کم زمان بودن از آنجا که خوشه‌بندی یک روش یادگیری بدون نظارت محسوب می‌گردد، در موارد بسیاری می‌تواند کاربرد داشته باشد. ( Ansari, Riasi ۲۰۱۶)</p>	<p>جواب نهایی به انتخاب خوشه‌های اولیه وابستگی دارد. روالی مشخص برای محاسبه اولیه مراکز خوشه‌ها وجود ندارد. اگر در تکراری از الگوریتم تعداد داده‌های متعلق به خوشه ای صفر شد راهی برای تغییر و بهبود ادامه روش وجود ندارد. در این روش فرض می‌شود که تعداد خوشه‌ها از ابتدا مشخص است. اما معمولاً در کاربردهای زیادی تعداد خوشه‌ها مشخص نمی‌باشد.</p>	<p>روش خوشه‌بندی k-means</p>
<p>SVM ها علی الخصوص زمانی که مجموعه داده‌ها بزرگ هستند کاربرد دارند. این مزیت از آنجا ناشی می‌شود که تنها یک زیرمجموعه از داده‌های آموزش (که به آنها بردارهای پشتیبان می‌گویند) برای تعیین تابع تصمیم استفاده می‌شود، در حالیکه می‌توان سایر نقاط را در نظر نگرفت. آموزش نسبتاً آسان، با تعداد کمی داده‌های آموزش به خوبی عمل می‌کند. برای داده‌های با ابعاد زیاد نسبتاً خوب عمل می‌کند.</p>	<p>نیاز به انتخاب تابع کرنل مناسب محدود بودن به دو صفحه خطی و نیاز به محاسبات زیاد، که البته ماشین‌های بردار پشتیبان تقریبی این مشکل را حل کرده‌اند.</p>	<p>ماشین‌های بردار پشتیبان</p>
<p>اجازه مدل‌سازی روابط داده‌های غیرخطی را می‌دهد. مدل ساخته شده می‌تواند متغیرهای کیفی را نیز شامل شود.</p>	<p>تخمین توابع ارزش حاشیه‌ای، وزن‌های مشخصه‌ها و مقدار برش با استفاده از تکنیک‌های برنامه‌ریزی خطی محاسبه می‌شوند که می‌تواند شامل معایب تکنیک‌های برنامه‌ریزی خطی گردد.</p>	<p>UTADI S</p>

در مورد اینکه کدامیک از این روش‌ها مناسب‌تر است باید اشاره کرد که عموماً هر محقق مدل خود را بهترین می‌داند. اما در تحقیقات گوناگون، محققین مختلف بین این روش‌ها مقایساتی انجام داده‌اند که بر اساس آنها نتایج کاملاً متناقضی حاصل شده است. شاید یکی از مهمترین دلایل حصول به نتایج متناقض، تفاوت زمان و جامعه آماری است. با این وجود باز هم برخی تلاش می‌کنند مدل‌هایی برای کاربرد عام طراحی کنند، به گونه‌ای که مدل در یک جامعه آماری طراحی و در جامعه آماری دیگری پیاده سازی شود. اگرچه هر کدام از این مدل‌ها بر جنبه‌ای خاص تکیه



می‌کنند، ولی تلاش شده از تحقیقاتی استفاده گردد که در مفروضات خود از داده‌های مالی استفاده کرده و نیز از اطلاعات موجود در بازارهای مالی به عنوان داده استفاده می‌کنند.

شایان ذکر است پژوهش حاضر توانسته رفتار مشتریان بانک را بر اساس شاخص‌های مالی و غیرمالی خوشه‌بندی نماید و نتایج حاصل از خوشه‌بندی را در مدل ریاضی تخصیص خدمات و محصولات بگونه‌ای بکار گرفته تا با ورود مشتریان اهداف از پیش تعیین شده مورد نظر بانک در مناسب‌ترین حالت خود قرار گیرند. با توجه آنکه جواب‌های مؤثر<sup>۱</sup> یا راه حل‌های غیر مسلط<sup>۲</sup> هر کدام از اهداف این تحقیق ممکن است جواب غیر مؤثر (مسلط) هدف دیگری باشند، بنابراین مسئله دارای جواب بهینه مطلق نمی‌باشد.

### ۳. شکاف تحقیق و تعریف مسئله

در حال حاضر بانک‌های تجاری در تحقق رسالت خویش چندان موفق نیستند. بالا بودن ذخایر بانک‌ها از یکسو و تسهیلات اعطایی سوخت‌شده و معوقه از سوی دیگر بیانگر عدم توجه کافی به مدیریت ریسک و عدم وجود مدیریت پرتفوی اعتباری در آنهاست (صالحی و اسکندری، ۱۳۹۳). بدیهی است در صورتیکه مدلی برای مدیریت پرتفوی اعتباری طراحی نشود و به عبارتی در پرتفوی تسهیلات اعطایی، تخصیص به‌درستی صورت نگیرد، بانک در بلندمدت با ورشکستگی مواجه خواهد شد، چرا که بودجه و سرمایه زیادی را به بعضی از تسهیلات اعطایی خود اختصاص می‌دهد که باعث افزایش ریسک اعتباری و در نتیجه احتمال عدم وصول مطالبات خواهد شد. مسائل و مشکلات مدیریت پرتفوی تسهیلات مهمترین دلیل ورشکستگی یا زیان‌دهی بانک‌ها و مؤسسات مالی و اعتباری می‌باشد (خواجوی و غیوری مقدم، ۱۳۹۲). مدل‌هایی مثل برنامه ریزی خطی، برنامه ریزی عدد صحیح، برنامه ریزی صفر و یک وجود دارند که می‌توانند ترکیبی بهینه از عناصر تشکیل دهنده سبد تسهیلات را ارائه دهند اما نمی‌توان برای رسیدن به چنین هدفی اطلاعات مالی را با در نظر گرفتن تمام شرایط وارد برنامه ریزی ریاضی کرد. بیشترین روش‌های انجام شده مربوط به چهار مدل مطرح شده با عنوان مدل‌های پرتفوی اعتباری به سه دسته مدل‌های ساختاری، مدل‌های بر مبنای کلان اقتصادی و مدل‌های مبتنی بر عملکرد گذشته، تقسیم بندی می‌شوند. مدل‌های ساختاری از داده‌ها و اقلام صورت‌های مالی و تغییرات ارزش دارایی‌ها در بازار سرمایه استفاده می‌نمایند. مدل‌های بر مبنای کلان اقتصادی، ریسک اعتباری را بر مبنای همبستگی و ارتباط صنایع با برخی از متغیرهای کلان اقتصادی محاسبه می‌کنند. مدل‌های آماری که همان مدل‌های مبتنی بر عملکرد گذشته هستند با استفاده از برخی توزیع‌های آماری، ریسک اعتباری را در بانک‌ها اندازه‌گیری نموده‌اند. فلذا بررسی سود و ریسک هر یک از مشتریان بانک در صورت اعطای تسهیلات در هیچ یک از مدل‌ها و روش‌های پیشین مطرح نبوده است. در صورتیکه در این پژوهش با استفاده از داده کاوی به بهینه سازی مدل چند هدفه تخصیص تسهیلات با استفاده از شبکه عصبی پرداخته شده است.

### ۴. روش شناسی

#### ۴.۱ ساختار بانک اطلاعاتی سازمان مورد پژوهش

برای بررسی متغیرهای مستقل و تشخیص نوع آنها و تحلیل داده‌ها از نرم افزار R استفاده شده است. نرم افزار R دارای محیطی شبیه نرم افزار Pl us-S بوده و برای انجام هر فعالیت در این نرم افزار باید از دستورها و کدهای مناسب، که اغلب شبیه دستورهای مورد استفاده در نرم افزار Pl us-S هستند استفاده کرد. داده‌ها به طور خلاصه بشرح ذیل می‌باشند که ۱۶۵۸ سطر و ۱۸ ستون دارا می‌باشد.

<sup>۱</sup> - Efficient solution  
<sup>۲</sup> - Non dominated solution

جدول (۳) متغیرهای تحقیق

```
> # structure of the data
> str(df)
tibble [1,658 x 18] (S3: tbl_df/tbl/data.frame)
 $ customer_type      : Factor w/ 2 levels "haghighi","hoghughi": 1 1 1 1 1 1 1 1 1 ...
 $ gender             : Factor w/ 3 levels "C","F","M": 3 2 2 3 3 3 3 3 3 ...
 $ loan_type          : Factor w/ 4 levels "morabehe","mosharekat_madani",...: 3 1 1 2 1 2 1 1 1 1 ...
 $ facility_type      : Factor w/ 2 levels "mobadele1","mosharekati": 1 1 1 2 1 2 1 1 1 1 ...
 $ customer_career    : Factor w/ 4 levels "azad","karmand",...: 1 2 2 2 NA 2 2 2 2 ...
 $ customer_income    : Factor w/ 3 levels "daramad_bala",...: 2 3 2 2 NA 2 2 2 2 ...
 $ loan_department    : Factor w/ 5 levels "bazargani","khadamat",...: 1 2 2 2 2 2 2 2 2 ...
 $ collateral_type    : Factor w/ 3 levels "1","2","3": 2 3 3 3 3 3 3 3 3 ...
 $ payment_date       : chr [1:1658] "1394/07/27" "1400/02/05" "1400/06/25" "1398/09/12" ...
 $ current_situation : Factor w/ 4 levels "faal","mashkukolvusul",...: 2 1 1 1 1 1 1 1 1 ...
 $ period             : num [1:1658] 180 1095 1095 1460 1460 ...
 $ approved_amount   : num [1:1658] 3.5e+08 6.0e+08 1.2e+09 1.0e+09 5.0e+08 1.0e+09 5.0e+08 5.0e+08 2.0e+08 3.0e+08 ...
 $ loan_remaining     : num [1:1658] 3.91e+08 5.21e+08 1.30e+09 5.81e+08 2.98e+08 ...
 $ interest_rate      : num [1:1658] 24 18 18 16 16 16 16 18 18 ...
 $ ghest              : num [1:1658] 62484034 21466922 42933843 28062608 14031304 ...
 $ profit_rate        : num [1:1658] 0.0266 0.0937 0.0937 0.1071 0.1071 ...
 $ income_or_cost     : num [1:1658] 0.9746 0.024 0.9759 0.0237 0.0239 ...
 $ risk               : num [1:1658] 0 0.333 0.639 0.333 0.333 ...
```

همانطور که می بینیم اکثر متغیرها از جنس فاکتور و اعداد می باشند به جز متغیر پرداخت تسهیلات که از جنس کاراکتر می باشد. در زبان برنامه نویسی R، مقدارهای متغیرهای طبقه ای را در یک متغیر عامل یا فاکتور ذخیره می کنند. البته ممکن است چنین مقدارهایی را در متغیرهای پیوسته نیز ذخیره کرد ولی کارایی و مفهوم طبقه ای بودن در چنین حالتی از آنها گرفته می شود.

## ۴,۲ آماده سازی داده ها

### ۴,۲,۱ پاک سازی داده<sup>۱</sup>

پاک سازی یا تمیز کردن داده ها به فرآیندی جهت تشخیص، حذف و اصلاح داده های نادرست از مجموعه جداول، رکوردها یا بانک های اطلاعاتی، همچنین شناسایی قسمت های ناقص و نادرست داده ها و سپس اصلاح و جایگزینی آنها اشاره دارد. هدف از پاک سازی داده ها استخراج اطلاعات دقیق و درست است، چرا که اطلاعات نادرست می تواند منجر به نتیجه گیری غلط شود. در این مرحله برخی از متغیرهای موجود در مجموعه داده های بدست آمده از بانک مورد نیاز محقق نمی باشد و این داده ها در ادامه فعالیت از مجموعه داده ها حذف گردیدند بطور مثال ستون هایی مانند ردیف، عنوان تسهیلات و ... از داده ها حذف گردیدند.

### ۴,۲,۲ تبدیل داده<sup>۲</sup>

گاهی اوقات برای اینکه دقت تجزیه و تحلیل را بالا ببریم باید در داده های خامی که برای تحلیل در دسترس ما قرار دارند، تغییراتی ایجاد کنیم، یکی از این تغییرات، فرایند تبدیل داده ها است. تبدیل داده ها روش هایی بر پایه ریاضی است که برای متغیرهایی به کار می رود که از شاخص های آماری نرمال بودن، خطی بودن، پراکندگی یکسان و ... پیروی نمی کنند. تبدیل داده نوعی روش تثبیت داده نیز به شمار می رود. در این فاز، داده های انتخاب شده به فرم دیگری تبدیل می شود. در این مرحله متغیرهایی که از جنس فاکتور بودند به کاراکتر تبدیل شدند و نوع وثیقه که

<sup>۱</sup>- Data Cleaning

<sup>۲</sup>- Data Transformation

بهبود پرداخت تسهیلات با در نظر گرفتن انضباط مالی و حداکثر سودآوری در شرایط عدم اطمینان

کاراکتر می بود به نوع عددی تبدیل شده‌اند. برای مباحث آمار و برنامه نویسی، متغیر عامل با فاکتور<sup>۱</sup>، دارای مقادیر عددی محدود است. این اعداد و ارقام اصولاً بصورت اعداد صحیح ثبت یا نمایش داده می‌شوند، از آنجائیکه برخی از این ستون‌ها فقط بصورت یک متن می‌باشند با کاراکتر نشان داده شده‌اند بقیه متغیرها نیز چون از نوع عددی هستند از نوع عددی<sup>۲</sup> تعریف شده‌اند. قبل از انجام هرگونه عملیات محقق تصمیم گرفته است که متغیرهای کاراکتری به متغیرهای فاکتور با استفاده از تابع as تبدیل گردد. که بشرح ذیل می‌باشد.

جدول (۴) تبدیل داده‌ها

```
tibble [1,658 x 18] (S3: tbl_df/tbl/data.frame)
 $ customer_type   : Factor w/ 2 levels "haghighi","hoghughi": 1 1 1 1 1 1 1 1 1 1 ...
 $ gender          : Factor w/ 3 levels "C","F","M": 3 2 2 3 3 3 3 3 3 3 ...
 $ loan_type       : Factor w/ 4 levels "morabehe","mosharekat_madani",...: 3 1 1 2 1 2 1 1 1 1 ...
 $ facility_type   : Factor w/ 2 levels "mobadelei","mosharekati": 1 1 1 2 1 2 1 1 1 1 ...
 $ customer_career : Factor w/ 4 levels "azad","karmand",...: 1 2 2 2 NA 2 2 2 2 2 ...
 $ customer_income : Factor w/ 3 levels "daramad_bala",...: 2 3 2 2 NA 2 2 2 2 2 ...
 $ loan_department : Factor w/ 5 levels "bazargani","khadamat",...: 1 2 2 2 2 2 2 2 2 2 ...
 $ collateral_type : Factor w/ 3 levels "1","2","3": 2 3 3 3 3 3 3 3 3 3 ...
 $ payment_date    : chr [1:1658] "1394/07/27" "1400/02/05" "1400/06/25" "1398/09/12" ...
 $ current_situation: Factor w/ 4 levels "faal","mashkukolvusu1",...: 2 1 1 1 1 1 1 1 1 1 ...
 $ period          : num [1:1658] 180 1095 1095 1460 1460 ...
 $ approved_amount : num [1:1658] 3.5e+08 6.0e+08 1.2e+09 1.0e+09 5.0e+08 1.0e+09 5.0e+08 5.0e+08 2.0e+08 3.0e+08 ...
 $ loan_remaining  : num [1:1658] 3.91e+08 5.21e+08 1.30e+09 5.81e+08 2.98e+08 ...
 $ interest_rate   : num [1:1658] 24 18 18 16 16 16 16 16 18 18 ...
 $ ghest           : num [1:1658] 62484034 21466922 42933843 28062608 14031304 ...
 $ profit_rate     : num [1:1658] 0.0266 0.0937 0.0937 0.1071 0.1071 ...
 $ income_or_cost  : num [1:1658] -1.95e+08 7.44e+06 -9.47e+06 4.49e+07 2.17e+07 ...
 $ risk            : num [1:1658] 100 0 4.21 0 0 ...
```

#### ۳.۲.۴ داده‌های گمشده<sup>۳</sup>

مسئله مقادیر گمشده در علم داده<sup>۴</sup> و بخصوص داده‌کاوی، زمانی رخ می‌دهد که یک یا چند مشاهده دارای مقدارهایی ثبت نشده یا ناموجود در ستون‌های «چارچوب اطلاعاتی»<sup>۵</sup> هستند. در چنین حالت می‌گوییم آن مشاهده دارای مقدار گمشده یا مقدار ناموجود است. در این حالت این مجموعه داده را دارای «داده گمشده» یا داده‌های گمشده می‌گوئیم. به منظور تحلیل‌های آماری روی مجموعه‌های اطلاعاتی با داده گمشده، باید مشخص کنیم که نقش چنین مشاهداتی در محاسبات مربوط به تحلیل آماری چگونه است. برای معرفی داده‌های گمشده در یک بردار از عبارت NA استفاده می‌کنیم. برای بررسی داده‌های گمشده در یک بردار از تابع `na.is()` استفاده می‌شود. این تابع برداری منطقی به طول بردار موردنظر ارائه می‌دهد که مقادیر گمشده متناظر با اعضای بردار در آن با TRUE نشان داده شده‌اند (Bhandari, 2022).

#### ۴.۲.۴ مدیریت داده‌های گم شده

روش‌های مختلفی برای مقابله با داده‌های از دست رفته وجود دارد، شاید راحت‌ترین روش، حذف نمونه‌هایی از داده‌های از دست رفته باشد. ولی در این روش تعداد نمونه‌ها کاهش پیدا می‌کند. همانطور که می‌دانید در داده‌کاوی هرچقدر تعداد نمونه‌ها بیشتر باشد مدلسازی با دقت بالاتری انجام می‌شود. گاهی می‌توان مقادیر خالی را با استفاده از الگوریتم‌های مختلف مقادیردهی نمود (Howell, 2021). در این پژوهش از روش نزدیکترین همسایه استفاده شده است. الگو کی - نزدیکترین همسایه<sup>۶</sup> یک متد آمار ناپارامتری است که برای طبقه‌بندی آماری و رگرسیون استفاده می‌شود (Du,

<sup>۱</sup> - factor

<sup>۲</sup> - numeric

<sup>۳</sup> -missing value

<sup>۴</sup> -data science


<sup>۵</sup> -data frame

<sup>۶</sup> -K- nearest neighbors algorithm

Li، ۲۰۱۹). در هر دو حالت k شامل نزدیکترین مثال آموزشی در فضای داده‌ای می‌باشد و خروجی آن بسته به نوع مورد استفاده در طبقه بندی و رگرسیون متغیر است. در حالت طبقه بندی با توجه به مقدار مشخص شده برای کی، به محاسبه فاصله نقطه‌ای که می‌خواهیم برچسب آن را مشخص کنیم با نزدیکترین نقاط می‌پردازد و با توجه به تعداد رأی حداکثری این نقاط همسایه، در رابطه با برچسب نقطه مورد نظر تصمیم‌گیری می‌کنیم (Huang، ۲۰۱۸). برای محاسبه این فاصله می‌توان از روش‌های مختلفی استفاده کرد که یکی از مطرح‌ترین این روش‌ها، فاصله اقلیدسی است (Estivill، Houle، ۲۰۰۱). در این پژوهش با استفاده از روش نزدیکترین همسایه، مقدار میانگین هر ستون بجای مقادیر گم‌شده جایگزین گردیده است.


### ۴,۲,۵ بصری‌سازی متغیرها

جهت تصویرسازی بهتر متغیرها استفاده از نمودار ggplot می‌گردد، نمودار تأثیر متغیرها روی متغیر وابسته که درآمد - هزینه یا ریسک می‌باشد به شرح زیر و به تصویر کشیده شده‌اند.



شکل (۱) تأثیر متغیر جنسیت بر متغیر وابسته هزینه/درآمد


در شکل شماره ۱ نشان داده شده است که تسهیلات پرداختی به اشخاص حقیقی با درآمد بالا و درآمد متوسط از نوع مرابحه بیشترین تأثیر را روی درآمد-هزینه بانک داشته است.



شکل (۲) تأثیر متغیر نوع تسهیلات بر متغیر وابسته هزینه/درآمد


طبق شکل شماره ۲ تسهیلات مرابحه و مشارکت مدنی پرداختی به اشخاص حقوقی بیشترین تأثیر را روی درآمد-هزینه بانک داشته است. در شکل شماره ۳ مشخص می‌باشد که تسهیلات مشارکت مدنی در بخش بازرگانی ریسک بیشتری داشته و مرابحه در بخش مسکن و خدمات به ترتیب ریسک کمتری داشته است.

بهبود پرداخت تسهیلات با در نظر گرفتن انضباط مالی و حداکثر سودآوری در شرایط عدم اطمینان



شکل (۳) تاثیر متغیر بخش تسهیلات بر متغیر وابسته ریسک

همچنان در شکل ۴ مشخص می‌باشد که تسهیلات مراجه در بخش خدمات و مسکن و مشارکت مدنی در بخش خدمات بیشترین تأثیر را روی درآمد- هزینه داشته است.



شکل (۴) تاثیر متغیر بخش تسهیلات بر متغیر وابسته هزینه/درآمد

#### ۶.۲.۴ نرمال سازی داده‌ها

نرمال سازی داده‌ها روشی برای یکنواخت کردن بازه مقادیر مربوط به متغیرهای مختلف پژوهش است و به بی‌مقیاس سازی داده‌ها نیز معروف است. اگر واحد سنجش متغیرهای مورد مطالعه متنوع باشد با استفاده از روش‌های نرمال سازی می‌توان داده‌ها را بی‌مقیاس کرد. مفهوم دیگر از نرمال کردن که به استاندارد کردن نیز موسوم است در تحلیل شبکه‌های عصبی مصنوعی و تحلیل پوششی داده‌ها کاربرد دارد. برای استاندارد کردن یک عنصر باید آن عنصر را میانگین کرده و بر انحراف معیار تقسیم نماید. استراتژی‌های ماکسیمین، ماکسیماکس و مینیمکس سه رویکرد تصمیم‌گیری تحت عدم اطمینان هستند که بخصوص در مسائل مالی و تصمیم‌گیری‌های اقتصادی، نقش مهمی دارند (Rahwanto, Wahyuningsih, Henderi, ۲۰۲۱). این گونه روش‌های انتخاب و تصمیم، برای اجرای یک فعالیت در استراتژی‌های مالی و بازار سهام نیز قابل استفاده است. برای اطمینان از بکارگیری روش مناسب جهت استاندارد سازی داده‌ها در این تحقیق از روش فازی یا همان روش ماکزیمم-مینیمم استفاده می‌شود. که این روش برای یک شاخص (Xj) با جنبه مثبت (مانند درآمد هر یک از تسهیلات) و یک شاخص با جنبه منفی مانند (ریسک و هزینه هر یک از تسهیلات) عبارت است از:

$$n_{ij}^- = \frac{x_{jMax} - x_{ij}}{x_{jMax} - x_{jMin}} n_{ij}^+ = \frac{x_{ij} - x_{jMin}}{x_{jMax} - x_{jMin}} \quad (1)$$

اعداد در این روش نرمال سازی دقیقاً بین صفر و یک خواهند بود بطوریکه فارغ از جنبه مثبت و منفی، صفر برای بدترین نتیجه و یک برای بهترین نتیجه می باشد (اصغرپور، ۱۳۸۸).


### ۴،۲،۷ حذف داده‌های پرت با استفاده از رویکرد z-score

یک روش متداول برای شناسایی و حذف داده‌های پرت استفاده از الگوریتم Z-score می باشد که بر اساس فاصله داده‌ها از میانگین و استاندارد داده‌ها محاسبه می شود. برای استفاده از این روش، ابتدا باید میانگین و استاندارد داده‌های مجموعه داده را محاسبه کرد. سپس برای هر داده، فاصله آن از میانگین را با استفاده از فرمول زیر محاسبه می کنیم:

$$z = (x - \mu) / \sigma \quad (۲)$$

که در این فرمول، X داده مورد نظر،  $\mu$  میانگین داده‌ها و  $\sigma$  انحراف معیار داده‌ها است.

زمانی که ما Z-score همه داده‌ها را محاسبه کردیم، می توانیم به داده‌های پرت پی ببریم. داده‌هایی که Z-score بیشتر از یک حداکثر مشخص مثلاً ۳ یا ۴ شده باشد به عنوان داده‌های پرت شناخته می شوند و می توانیم آنها را از مجموعه داده حذف کنیم. شکل زیر حالت کلی استفاده از این روش می باشد.



شکل (۵) Z-score

باتوجه به اینکه تعداد داده‌های این پژوهش زیاد نمی باشد در حذف داده‌های پرت محتاط بوده به همین دلیل داده‌های پرت بزرگتر از ۴ حذف گردیده است.

### ۴،۲،۸ خوشه بندی متغیرها

خوشه بندی، فرآیندی است که به کمک آن می توان مجموعه‌ای از اشیاء را به گروه‌های مجزا افراز کرد. هر افراز یک خوشه نامیده می شود. اعضاء هر خوشه با توجه به ویژگی‌هایی که دارند به یکدیگر بسیار شبیه هستند و در عوض میزان شباهت بین خوشه‌ها کمترین مقدار است. در چنین حالتی هدف از خوشه بندی، نسبت دادن برچسب‌هایی به اشیاء است که نشان دهنده عضویت هر شیء به خوشه است (Bock, ۲۰۰۷). در این پژوهش با استفاده از معیار سیلوئیت تعداد بهینه خوشه با استفاده از فرمول زیر در نرم افزار R-Studio بدست آمده است:

$$avg = function(k) \{ \quad (۳)$$

```

km.res = kmeans(df.n, centers = k, nstart = ۲۵)
ss = silhouette(km.res$cluster, dist(df.n))
return(mean(ss[,۳]))
}
k.values = ۲:۶
avg.sil = map_dbl(k.values, avg)
fviz_nbclust(df.n, kmeans, method = "silhouette")
df.n <- df %>%
dplyr::select(approved_amount, loan_remaining, profit_rate, income_or_cost, risk)

```

روش SC<sup>۱</sup> یکی از متداولترین و بهترین روش‌های اعتبار سنجی الگوریتم خوشه‌بندی کا-میانه<sup>۲</sup> می‌باشد. که اولین بار توسط کافمن و روسیو در سال ۱۹۹۰ پیشنهاد شد. که در این رابطه همبستگی  $a(x)$  متوسط فاصله  $(X)$  نسبت به بردارهای دیگر در همان خوشه است، شاخص تفکیک  $b(x)$  متوسط فاصله  $(X)$  نسبت به سایر خوشه‌ها را نشان می‌دهد  $S(x)$  نمایش اندازه گیری میزان نزدیکی هر نقطه در یک خوشه است، که امتیاز آنها نسبت به خوشه‌های مجاورش سنجیده می‌شود. محدوده امتیاز دهی آن بین ۰ و ۱+ است (Chen, Bose, ۲۰۱۵). به این صورت که اگر این اندازه گیری در محدوده ۱+ باشد نشان دهنده این است که خوشه مورد نظر نسبت به خوشه مجاورش بسیار دور است. و حالت صفر نشان می‌دهد که هیچ گونه تفکیکی بین خوشه مورد نظر و خوشه‌های همسایه وجود ندارد. و بالاخره حالت ۱- نشان دهنده احتمالات اختصاص خوشه مورد نظر به صورت غلط است. که نتیجه به دست آمده از روش فوق به شکل زیر می‌باشد:


Within cluster sum of squares by cluster

(۴)

$$۷. ۱۳۴۰۰۴ \square + ۲۴ \quad ۱. ۲۵۳۲۱۱ \square + ۲۴$$

(% between\_SS / total\_SS = ۷۵. ۴)

همانگونه که از خروجی مشخص می‌باشد total-ss میزان ۷۵/۴٪ را به خود اختصاص داده که نشانگر این موضوع است که به درستی خوشه‌ها انتخاب شده‌اند. چنانچه از شکل زیر مشخص می‌باشد بهترین تعداد خوشه دو می‌باشد.



شکل (۶) تعداد بهینه خوشه

<sup>۱</sup> - Silhouette Coefficient

<sup>۲</sup> - K-Means


### ۴,۲,۹ روش خوشه‌بندی کا-میانه<sup>۱</sup>

الگوریتم کا-میانه الگوریتمی مبتنی بر شیء می‌باشد و نماینده‌ی خوشه‌ها را از میان خود داده‌ها و نه میانگین‌گیری از آنها انتخاب می‌کند. در واقع medoids یک خوشه، مرکزی‌ترین عنصر یک خوشه است. هدف این روش، کم کردن حساسیت نسبت به مقادیر بزرگ در مجموعه داده‌هاست. در این الگوریتم هر خوشه با یکی از داده‌های نزدیک به مرکز معرفی می‌شود (Guo & others, ۲۰۰۳). نحوه‌ی محاسبه کا-میانه بصورت زیر می‌باشد:

`knmedoids.re<-pam(df.n, k=۲, metric = "euclidean", stand = FALSE)` (۵)

`knmedoids.re<-pam(df.n, k=۲, metric = "manhattan", stand = FALSE)`

همانطور که مشاهده می‌شود تعداد بهینه خوشه ۲ بوده و از فاصله اقلیدسی و منتهن برای خوشه‌بندی استفاده گردیده است که نتیجه هر دو یکسان و به شکل زیر می‌باشد:



شکل (۷) خوشه‌بندی کا-میانه

نتیجه خوشه‌بندی با روش کا-میانه بشرح ذیل می‌باشد:

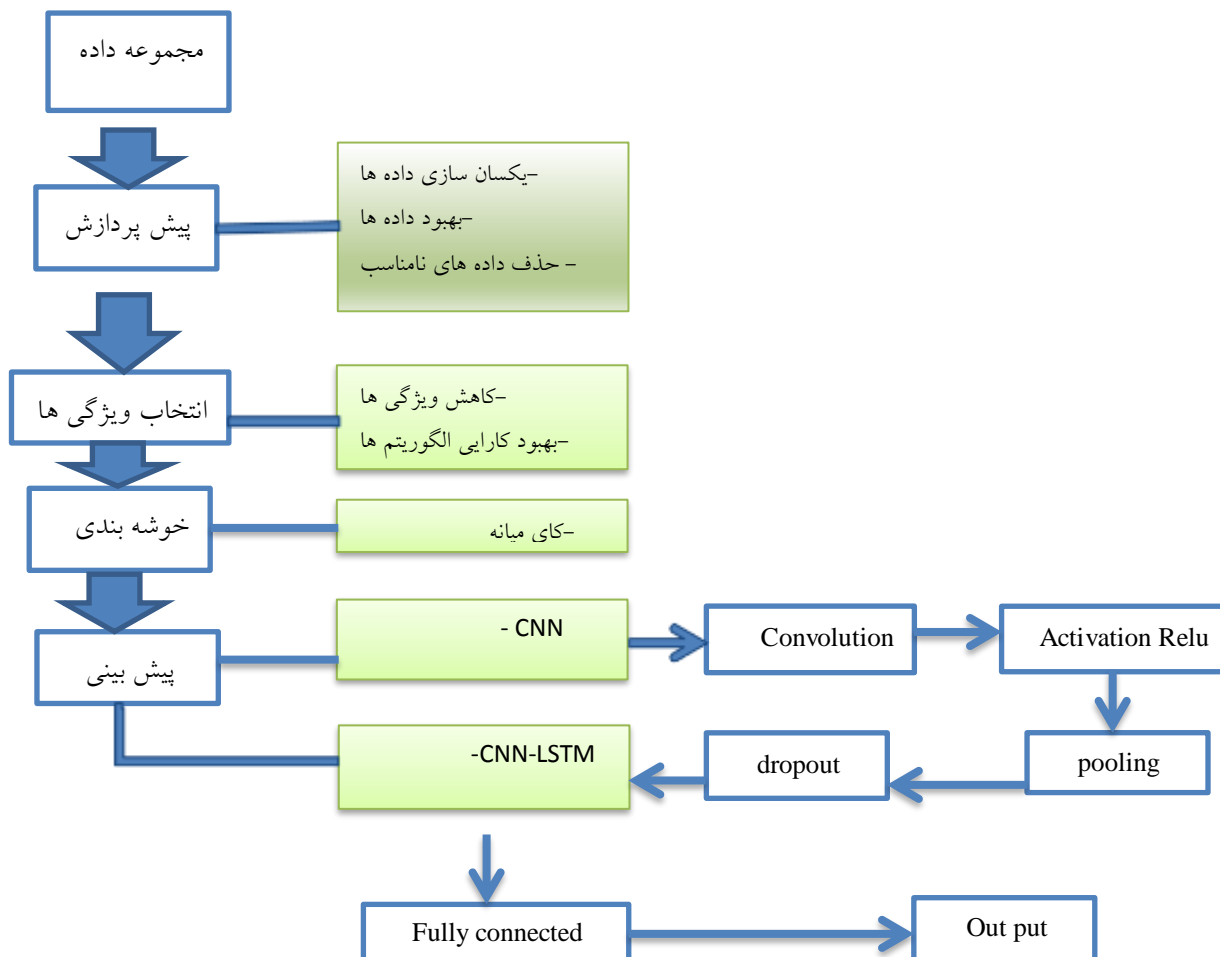
Medoids:

	ID	approved_amount	loan_remaining	ghest	profit_rate	income_or_cost	risk
[1,]	1148	5.000000e+08	4.157526e+08	17889101	0.09369886	7893890	0.00000
[2,]	1424	1.204945e+12	1.600629e+12	93028258643	0.06284257	-24865811247	16.41918

که نشانگر این می‌باشد که مشتریان در دو گروه مشتریان خوش حساب و مشتریان بدحساب طبقه بندی گردیده‌اند که مشتریان خوش حساب دارای درآمد مثبت و ریسک صفر بوده و مشتریان بد حساب دارای ریسک ۱۶.۴۲ و درآمد منفی یا بهتر است ذکر کنیم برای بانک دارای هزینه بوده‌اند.



## ۵. چارچوب پژوهش



شکل (۸) چارچوب پژوهش

## ۶. یافته‌های پژوهش

### ۶.۱ یادگیری عمیق با استفاده از شبکه‌های عصبی

یادگیری عمیق از شبکه‌های عصبی مصنوعی برای انجام محاسبات پیچیده بر روی حجم زیادی از داده‌ها استفاده می‌کند. یادگیری عمیق، نوعی از یادگیری ماشین است (Ngufor & others, ۲۰۱۹)، که بر اساس ساختار و عملکرد مغز انسان کار می‌کند (Adnan, ۲۰۲۰). یادگیری عمیق زیر مجموعه‌ای از هوش مصنوعی است که در آن به جای انسان از ماشین استفاده می‌شود در ابتدا باید بگوییم که مغز انسان از رشته‌های عصبی تشکیل شده است که این عصب‌ها با هم در ارتباط‌اند و پردازش اطلاعات می‌کنند کارهایی که انجام می‌دهیم براساس ورودی‌هایی است که دریافت می‌کنیم و در اصل مغز ما مانند یک تابع رفتار می‌کند که ورودی‌هایی را می‌گیرد و عملیات انجام می‌دهد و خروجی به ما تحویل می‌دهد یادگیری عمیق نیز با استفاده از شبکه عصبی عمیق که مانند مغز انسان عمل می‌کند و پردازش انجام می‌دهد (Al Machot & others, ۲۰۱۵). شبکه عصبی توسط

ورودی‌ها آموزش داده می‌شود و شامل سه لایه ورودی و پنهان و خروجی است و هر کدام از عصب‌ها دارای مقدار آستانه و تابع فعال‌سازی می‌باشند که به ما خروجی می‌دهند نتیجه‌ای که به دست می‌آوریم با خروجی که انتظار داریم مقایسه می‌شود که این دو مقدار باید نزدیک به هم باشند، مدل یاد می‌گیرد که وزن‌ها و مقدار آستانه را طوری تنظیم کند که خروجی درست دریافت کند. لایه‌های شبکه‌ی عصبی، از گره‌ها تشکیل شده‌اند. یک گره، مانند نورون‌های مغز انسان، مکانی برای انجام محاسبات است. مجموعه‌ای از نورون‌های فعال شده منجر به یادگیری می‌شوند (شریف فر، ۱۴۰۱).

### ۶,۱,۱ شبکه عصبی CNN

CNN از گیرنده‌های چند لایه تشکیل شده است منظور از گیرنده‌های چند لایه شبکه‌های کاملاً متصل هستند، که هر نورون در یک لایه به همه سلول‌های عصبی در لایه بعدی متصل می‌شود اتصال کامل این شبکه‌ها موجب می‌شود که بیش از حد از داده‌ها استفاده کنند CNN ها از الگوی سلسله‌مراتبی در داده‌ها استفاده می‌کنند و با استفاده از الگوهای کوچکتر و ساده الگوهای پیچیده‌تری را بدست می‌آورند (Oquab & others, ۲۰۱۴). ورودی بیشتر مدل‌های یادگیری عمیق مانند شبکه عصبی باید به صورت عدد باشند به همین منظور داده‌های کیفی را باید در مرحله پیش پردازش داده‌ها به صورت عدد تبدیل شوند. در مدل‌های یادگیری عمیق، برای داده‌هایی که به صورت دسته‌ای هستند (مثلاً در این مجموعه داده ایی ویژگی نوع مشتری)، باید قبل از اعمال مدل، آنها را به صورت عددی تبدیل کرد. روش رمزگذاری به صورت برجسب یکی از روش‌های تبدیل داده‌های کیفی به داده‌های عددی می‌باشد (Krizhevsky & others, ۲۰۱۷). در این پژوهش، برای هر دسته یک عدد مخصوص تعیین گردید. به عنوان مثال برای ویژگی نوع مشتری، برای حقیقی، حقوقی به ترتیب می‌توان عدد ۱ و ۲ را نسبت داد. سپس برای هر داده، مقدار عددی مخصوص آن دسته برای آن نمونه انتخاب گردید. همچنین بخش آموزش برای آموزش مدل‌های یادگیری عمیق استفاده می‌شود، بخش آزمایش برای ارزیابی عملکرد مدل‌ها بر روی داده‌های جدید استفاده می‌شود و بخش اعتبارسنجی برای تنظیم پارامترهای مدل و انتخاب بهترین مدل از بین چندین مدل مختلف استفاده می‌شود (Ole Hjelkrem, Eilif de Lange, ۲۰۲۳). برای تقسیم مجموعه داده به سه بخش، معمولاً از روش تصادفی استفاده گردیده است. در این تحقیق، ۷۰٪ از داده‌ها به بخش آموزش، ۱۵٪ به بخش آزمایش و ۱۵٪ به بخش اعتبارسنجی تخصیص داده شده است. در این پژوهش مدل به صورت لایه به لایه تعریف شده است. در ابتدا، یک لایه کانولوشن با ۶۴ فیلتر، اندازه کرنل ۳ و تابع فعال‌سازی relu تعریف شده است. سپس یک لایه MaxPooling با اندازه ۲ تعریف شده است که به منظور کاهش ابعاد داده‌ها استفاده شده است. این لایه با انتخاب بزرگترین مقدار در هر دو مقدار داده‌های ورودی، ابعاد داده‌ها را نصف می‌کند. برای جلوگیری از بیش‌برازش، یک لایه Dropout با مقدار ۰/۵ تعریف شده است. این لایه به منظور حذف تصادفی وزن‌های یادگیری مدل استفاده می‌شود و در اینجا مقدار ۰/۵ به این معنی است که در هر دوره ۵۰ درصد از وزن‌های مدل به صورت تصادفی حذف می‌شوند. پس از آن، یک لایه Flatten تعریف شده است که به منظور تبدیل داده‌های ورودی به داده‌های یک بعدی استفاده می‌شود. این لایه به صورت خطی داده‌های ورودی را به یک بعد تبدیل می‌کند تا بتواند به لایه Dense بعدی داده شوند. در نهایت، دو لایه Dense تعریف شده است. لایه اول با ۱۲۸ نورون و تابع فعال‌سازی relu تعریف شده است و لایه دوم با دو نورون و بدون فعال‌سازی تعریف شده است.

### ۶,۱,۲ مدل CNN-LSTM

این مدل شامل چند لایه است. ابتدا، یک لایه کانولوشن با ۸ فیلتر، اندازه کرنل ۳ تعریف شده است. سپس یک لایه LSTM با ۶۴ نورون و بازگشت دنباله‌های خروجی تعریف شده است. این لایه به منظور یادگیری الگوهای طولانی مدت در داده‌های ورودی استفاده می‌شود. تنظیم return\_sequences=True به LSTM می‌گوید که برای تمام داده‌های ورودی، خروجی تولید کند. پس از آن، یک لایه MaxPooling با اندازه ۲ تعریف شده است. این لایه با انتخاب بزرگترین مقدار در هر دو مقدار داده‌های ورودی، ابعاد داده‌ها را نصف می‌کند. سپس، یک لایه

Flatten تعریف شده است که به منظور تبدیل داده‌های ورودی به داده‌های یک بعدی استفاده می‌شود. در نهایت، یک لایه Dense با دو نورون و بدون فعال‌سازی تعریف شده است.


## ۶.۲ پارامترهای کامپایل برای مدل‌های CNN و CNN-LSTM

سه پارامتر بهینه‌ساز، ضرر و متریک برای هر دو مدل CNN و CNN-LSTM یکسان در نظر گرفته شده است تا مقایسه دقت‌های دو مدل در شرایط یکسان بررسی شود.


- پارامتر بهینه‌ساز، الگوریتم بهینه‌سازی است که در فرایند آموزش مدل‌ها مورد استفاده قرار می‌گیرد. در اینجا، الگوریتم بهینه‌سازی آدام انتخاب شده است.
- پارامتر ضرر، تابع هزینه است که در فرایند آموزش مدل مورد استفاده قرار می‌گیرد. در اینجا، تابع هزینه میانگین مربعات خطا انتخاب شده است. این تابع هزینه برای مسائل رگرسیون مناسب است.
- پارامتر متریک، معیارهایی است که در فرایند آموزش مدل جهت ارزیابی عملکرد مدل استفاده می‌شوند (Dormann, 2013). در اینجا، معیار دقت انتخاب شده است. این معیار برای مسائل دسته‌بندی مناسب است و نشان می‌دهد که چه درصد از داده‌های آزمون به درستی دسته‌بندی شده‌اند.

## ۷. تحلیل یافته‌ها

نمودارهای دقت و خطا مدل‌های CNN و CNN-LSTM به شرح زیر می‌باشد. این نمودارها به ما کمک می‌کند که فرآیند آموزش مدل به چه صورت انجام گردیده است. تعداد مراحل آموزش برای هر دو مدل برابر با ۱۰۰ در نظر گرفته شده است. شکل‌های شماره ۸ و ۹ به ترتیب مربوط به نمودارهای دقت و خطا برای مدل CNN در فرآیند آموزش می‌باشد. نمودار آبی رنگ مربوط به میزان دقت و خطا مدل برای داده‌های آموزش و نمودار نارنجی برای دقت و خطا مدل بر روی داده‌های اعتبارسنجی می‌باشد. همانطور که از نمودار دقت مشخص است در همان مراحل ابتدایی مدل توانسته به برازش نسبتاً کاملی از داده‌ها دست پیدا کند. به طوری که هم دقت مدل بر روی داده‌های آموزش و هم داده‌های اعتبارسنجی در هر مرحله از دقت بالای ۹۷٪/۵ برخوردار هستند و از طرفی میزان خطا هم در همان مراحل ابتدایی به زیر ۱٪ رسیده است. در نتیجه پس با قطعیت می‌توانیم بگوییم که در فرآیند آموزش مدل CNN بیش برازش رخ نداده است و مدل با موفقیت توانسته داده‌ها را برازش کند.




شکل (۹) نمودار دقت مدل CNN




شکل (۱۰) نمودار خطای مدل CNN

همچنین نمودار دقت و خطا مدل CNN-LSTM به شکل زیر می‌باشد. همانگونه که مشخص است، شکل های زیر به ترتیب مربوط به نمودارهای دقت و خطا برای مدل CNN-LSTM در فرآیند آموزش می‌باشد. نمودار آبی رنگ مربوط به میزان دقت و خطا مدل برای داده‌های آموزش و نمودار نارنجی برای دقت و خطا مدل بر روی داده‌های اعتبارسنجی می‌باشد. مدل CNN-LSTM برخلاف مدل CNN در همان توانسته به صورت پایدار به برازش نسبتاً کاملی از داده‌ها دست پیدا کند و بعد از مرحله ۱۲۰ام آموزش دقت مدل بر روی داده‌های هر چند مرحله یک بار افزایش و کاهش پیدا می‌کند به نحوی که حتی در مراحل آخر آموزش دقت مدل بر روی داده‌های آموزش به کاهش بیشتری پیدا می‌کند. اما در مجموع مدل موفقیت آمیز بوده است چرا که کمترین میزان دقت بر روی داده‌های آموزش و اعتبارسنجی به ترتیب ۹۷٪/۸۵ و ۹۷٪/۷۰ بوده است. از طرفی دیگر نیز خطای مدل همواره رو به کاهش بوده است به طوری که میزان خطا در همان مراحل ابتدایی به زیر ۰٪/۵ رسیده است. این امر با توجه به میزان دقت مدل نشانگر این موضوع است که مدل دچار بیش برازش نشده است و در نهایت مدل نسبتاً کاملی از داده‌ها برازش شده است.



شکل (۱۱) نمودار دقت مدل CNN-LSTM

بهبود پرداخت تسهیلات با در نظر گرفتن انضباط مالی و حداکثر سودآوری در شرایط عدم اطمینان



شکل (۱۲) نمودار خطای مدل CNN-LSTM

## نتیجه گیری

مؤسسات مالی در ساختار اقتصادی جوامع از اهمیت بالایی برخوردارند. این مؤسسات به عنوان قلب اقتصاد در دو بازار سرمایه و پول فعالیت داشته و باعث ایجاد جریان نقدینگی می گردند. در اقتصاد ایران حتی، اهمیت این مؤسسات دو چندان می شود چرا که آنها علاوه بر واسطه‌ی وجوه بودن در بازار پول، به دلیل عدم توسعه کافی بازار سرمایه، نقش اساسی در تأمین مالی برنامه‌های میان مدت و بلندمدت اقتصادی کشور ایفا می کنند. بنابراین مبحث سودآوری در این نوع مؤسسات نه تنها برای خود آنها که برای کل اقتصاد حائز ارزش می گردد. این پژوهش در ابتدا به دنبال شناسایی عوامل مؤثر بر سودآوری بانک‌ها و کاهش ریسک داشته و با جداسازی تأثیرات عوامل مختلف، به طور خاص بر کارکرد آنها تمرکز کرده و تأثیر عوامل کارکردی شعب را بر روی سودآوری و ریسک بررسی نموده است. برای رسیدن به هدف مذکور ابتدا از تکنیک‌های خوشه‌بندی برای جدا کردن مشتریان به دو گروه مشتریان خوش حساب و بدحساب استفاده گردید و سپس به بررسی عوامل مؤثر بر افزایش سودآوری و کاهش ریسک پرداخته شده است. هدف این پژوهش طراحی یک مدل یادگیری عمیق CNN و CNN-LSTM بوده است. سپس به برآورد ریسک و سود با مدل موردنظر پرداخته شده است. در مقایسه دقت مدل‌های CNN و CNN-LSTM بر روی داده‌های آزمایش می توان گفت میزان دقت مدل CNN بر روی داده‌های آزمایش برابر با ۹۸٪/۲۳ می باشد. دقت مدل CNN-LSTM بر روی همان داده‌های آزمایش برابر با ۹۷٪/۷۸ می باشد. با توجه به اینکه هر دو مدل در شرایط یکسانی آموزش دیده‌اند و پارامترهای یادگیری هر دو دقیقاً باهم برابر بوده است و با توجه به پایداری بیشتر مدل CNN در فرآیند آموزش و دقت بالاتر آن بر روی داده‌های آزمایش می توان نتیجه گرفت که مدل CNN بهتر از مدل CNN-LSTM عمل کرده است. اما در کل هر دو مدل توانسته اند دقت خوبی بر روی داده‌های آزمایش بدست بیاورند.

## پیشنهادات کاربردی

با توجه به بکارگیری عوامل مؤثر در پرداخت تسهیلات، در بانک‌ها می توان با داشتن هریک از پارامترهای مشتریان آنها را در هریک از دو دسته مشتریان بد حساب یا خوش حساب خوشه‌بندی نمود علاوه بر آن می توان پیش‌بینی نمود مشتری با ویژگی‌های شخصیتی و درآمدی و با توجه به نوع و مبلغ وام آیا توان باز پرداخت تسهیلات را دارا می باشد یا خیر؟ و اگر به مشتری وامی پرداخت شود ریسک و سود مربوط به هر وام چقدر می باشد.

## تحقیقات آتی

پژوهشگران آتی می‌توانند از بقیه مدل‌های یادگیری عمیق نیز برای مباحث پیش‌بینی استفاده نمایند. همچنین آنها می‌توانند از یافته‌های این تحقیق در بقیه مسائل مالی و مدیریتی استفاده نمایند.

## منابع

- اصغر پور، حسین، (۱۳۸۸). اثر بی ثباتی سیاسی بر رشد اقتصادی ایران: رهیافت غیر خطی APARCH. خواجه‌سوی، شکراله، غیوری مقدم، علی، (۱۳۹۲). بررسی کاربرد تحلیل پوششی داده‌ها در مقایسه و ارزیابی عملکرد واحدهای تجاری. دامی، سینا، خیری، فرشته، (۱۳۹۷). شناسایی تقلب در پرداخت کارت های اعتباری با شبکه عصبی حافظه طولانی کوتاه مدت (LSTM). سومین کنفرانس ملی فناوری در مهندسی برق و کامپیوتر
- راعی، رضا، فرهادی، روح‌الله، شیروانی، امیر، (۱۳۹۰). رابطه در گذر زمان بین بازده و ریسک: شواهدی از الگوی قیمت گذاری دارایی سرمایه ای در گذر زمان *ICAPM* فصلنامه چشم انداز مدیریت مالی دانشگاه شهید بهشتی، تهران.
- شریف فر، امیر، خلیلی عراقی، مریم، رئیسی وانانی، ایمان، فلاح شمس، میر فیض، (۱۴۰۱). کاربرد معماری‌های یادگیری عمیق در پیش‌بینی قیمت سهام (رویکرد شبکه عصبی پیچشی CNN)، دوره ۱۰، شماره ۳، صفحه ۲۰-۱.
- صالحی، فهمیه، صالحی، مجتبی، اسکندری، میثم (۱۳۹۳). بهینه سازی سبد تسهیلات اعطایی موسسات مالی با استفاده از برنامه ریزی ریاضی و الگوریتم ژنتیک (مطالعه موردی بانک تجارت)، فصلنامه توسعه‌ی مدیریت پولی و بانکی، دوره ۲، شماره ۳.
- عسگر زاده، مجید، و دیگران، (۱۳۸۶). بررسی ریسک عملیاتی بانکداری الکترونیکی یکپارچه و ارائه‌ی راهکارهای کاهش مخاطرات آن، اولین کنفرانس جهانی بانکداری الکترونیک.

## References

- Ansari, A., Riasi, A., (۲۰۱۶). *Customer Clustering Using a Combination of Fuzzy C-Means and Genetic Algorithms*.
- Adnan et al, R.M., (۲۰۲۰). *Least square support vector machine and multivariate adaptive regression splines for streamflow prediction in mountainous basin using hydro-meteorological data as inputs*, J. Hydrol.
- Armantier, O., Ghysels, E., Sarkar, A., Shrader, J., (۲۰۱۵). *Discount window stigma during the 2007-2008 financial crisis*. *J. Financ. Econ.* ۱۱۸ (۲), ۳۱۷-۳۳۵.
- Al Machot, F. et al., (۲۰۱۹). *A deep-learning model for subject-independent human emotion recognition using electrodermal activity sensors*.
- Bock, H., (۲۰۰۷). *Clustering methods: A history of k-means algorithms Selected Contributions in Data Analysis and Classification*, ۱۶۱-۱۷۲.
- Bhandari, P., (۲۰۲۲). *Missing Data | Types, Explanation, & Imputation*. Revised on November ۱۱, ۲۰۲۲.
- Bernanke, B., (۲۰۰۹). *The federal reserve's balance sheet: an update*. In: *A Speech at the Federal Reserve Board Conference on Key Developments in Monetary Policy*, Washington, D.C.
- Bose, I., Chen, X., (۲۰۱۵). *Detecting the migration of mobile service customers using fuzzy clustering*.
- Chen, X.D., (۲۰۱۷). *Analysis and research of common clustering algorithm in data mining* *Digital Technol. Appl.*, pp. ۱۵۱-۱۵۲.
- Du S., Li J., (۲۰۱۹). *Parallel processing of improved knn text classification algorithm based on Hadoop*. In: *2019 7th International Conference on Information, Communication and Networks (ICICN)*, ۱۶۷-۱۷۰.
- Dormann et al, C.F., (۲۰۱۳). *Collinearity: a review of methods to deal with it and a simulation study evaluating their performance*.
- Estivill-Castro V., Houle M.E., (۲۰۰۱). *Robust distance-based clustering with applications to spatial data mining*, *Algorithmica*, ۳۰ (۲), ۲۱۶-۲۴۲.
- Guo, G., Wang, H., Bell, D., Greer, Y., (۲۰۰۳). *KNN model-based approach in classification* *OTM Confederated International Conferences on the Move to Meaningful Internet Systems*, ۹۸۶-۹۹۶.

- Howell, E., (۲۰۲۱). *4 Techniques To Deal With Missing Data in Datasets, Simple methods that can nullify the effects of missing values, Published in Towards Data Science, Sep ۱۷.*
- Huang, X.Y. , (۲۰۱۸). *An improved KNN algorithm and its application in real-time car-sharing prediction., Dalian University of Technology, Daian, China ,M.S. thesis.*
- Huang et al., Huang J., Wei Y., Yi J., Liu M., (۲۰۱۸). *An improved KNN based on class contribution and feature weighting. In: 2018 10th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA), ۳۱۳-۳۱۶.*
- Henderi, T., Wahyuningsih, T., Rahwanto, E., (۲۰۲۱). *Comparison of Min-Max normalization and Z-Score Normalization in the K-nearest neighbor (KNN) Algorithm to The Accuracy of Type Breast Cance, International Journal of Informatics and Information System Vol. ۴, NO. ۱, ۱۳-۲۰.*
- Khosroyani, M., Heydarpoor, F., Yaghoob-nezhad, A., & Poorzamani, Z., (۲۰۲۲). *An artificial neural network model for predicting the liquidity risk of Iranian private banks. Int. J. Nonlinear Anal. In Press, ۱-۱۱ ISSN: ۲۰۰۸-۶۸۲۲ (electronic); <http://dx.doi.org/۱۰.۲۲۰۷۰/ijnaa.۲۰۲۲.۲۹۱۱۸.۴۰۷۱>. [In Persian].*
- Khalila, S., Amritb, CH, Kocha, T, Dugundjia, E., (۲۰۲۱). *Forecasting public transport ridership: Management of Information system by using CNN and LSTM Architecture, The 12th International Conference on Ambient Systems, Networks and Technologies (ANT).*
- Krizhevsky, A., Sutskever, I., Hinton, G.E., (۲۰۱۷). *Imagenet classification with deep convolutional neural networks. Communications of the ACM ۶۰, ۸۴ - ۹۰. URL: <https://search.ebscohost.com.proxy.uba.uva.nl:۲۴۴۳/login.aspx?direct=true&db=buh&AN=۱۲۳۴۴۶۱۰۲&site=ehost-live&scope=site>.*
- Mohammadi, N., Zangeneh, M., (۲۰۱۶). *Customer credit risk assessment using artificial neural networks IJ Information Technology and Computer Science, ۸ (۳), ۵۸-۶۶.*
- Ngufor, C., Van Houten, H., Caffo, B.S., Shah, N.D., McCoy, R.G., (۲۰۱۹). *Mixed Effect Machine Learning: a framework for predicting longitudinal change in hemoglobin A1c. J. Biomed. Inform, ۵۶-۶۷*
- Ole Hjelkrem, L., Eilif de Lange, P., (۲۰۲۳). *Explaining Deep Learning Models for Credit Scoring with SHAP: A Case Study Using Open Banking Data, J. Risk Financial Management., ۱۶(۴), ۲۲۱; <https://doi.org/۱۰.۳۳۹۰/jrfm۱۶۰۴۰۲۲۱>.*
- Oquab, M., Bottou, L., Laptev, I., Sivic, J., (۲۰۱۴). *Learning and Transferring Mid-Level Image Representations using Convolutional Neural Networks, in: IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, United States. URL: <https://hal.inria.fr/hal-۰۰۹۱۱۱۷۹>. conference version of the paper.*