

## **Development and Explanation of Bank Customers' Credit System Based on Hybrid Learning Models: A Case Study of Bank Mellat**

**Ali Ghasemi Armaky\*, Mirfeiz Fallah\*\*, Mahmoud Alborzi\*\*\***

Research Paper

### **Abstract**

The possibility to renewal of loan contracts in Iran may lead to the identification of fictitious profits by banks and ultimately lead to a banking crisis and disruption of the country's monetary system, so to prevent banks from reaching the stage of this, Measuring customers' credit risk is essential. The aim of this study is to increase the accuracy of customer accreditation using the structure of hybrid models and has been done as a case study on Mellat Bank. In this regard, 14 learning models were compared with each other and their ability to validate customers was determined. Learning models show that based on both accuracy criteria (success rate) and measurement F (harmonic mean between accuracy and recall), the combined learning model (KNN-NN-SVMPSO) - (DL) - (DBSCAN) with an accuracy rate of 99.90 is the highest It has more performance than other basic and hybrid models. Also, using the principal component analysis (PCA), Gini index, interest rate ratio (IGR) and interest rate (IG) methods to calculate the weight of features and their average rank, it was shown that features such as collateral, The type of collateral and the amount of facilities have been the most important features in distinguishing good from bad customers, respectively.

**Keywords: Credit Risk; Machine Learning; Good Customers; Bad Customers.**

Received: 2021. September. 18, Accepted: 2021. November. 10.

\* Ph.D. Candidate in Financial Management, Qazvin Branch, Islamic Azad University, Qazvin, Iran.  
E-Mail: [alghasemy@yahoo.com](mailto:alghasemy@yahoo.com)

\*\* Associate prof., Department of Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. (Corresponding Author). E-Mail: [mir.fallahshams@iauctb.ac.ir](mailto:mir.fallahshams@iauctb.ac.ir)

\*\*\* Associate Prof., Department of Management, Science and Research Branch, Islamic Azad University, Tehran, Iran.

## توسعه و تبیین نظام اعتبارسنجی مشتریان بانک‌ها بر اساس مدل‌های هیبریدی فرایادگیر: مورد مطالعه، بانک ملت

علی قاسمی ارمکی\*، میرفیض فلاح\*\*، محمود البرزی\*\*\*

مقاله پژوهشی

### چکیده

امکان استمهال و تجدید قراردادهای تسهیلات در ایران ممکن است منجر به شناسایی سود موهومی توسط بانک‌ها شده و در نهایت بحران بانکی و اخلال در نظام پولی کشور را در پی داشته باشد، لذا برای جلوگیری از رسیدن بانک‌ها به مرحله استمهال و تجدید قراردادهای، سنجش ریسک اعتباری مشتریان بسیار ضروری است. هدف پژوهش حاضر افزایش دقت و صحت اعتبارسنجی مشتریان، با استفاده از ساختار مدل‌های هیبریدی بوده و به صورت مطالعه موردی بر روی بانک ملت انجام شده است. در این راستا ۱۴ مدل یادگیرنده با یکدیگر مقایسه و میزان توانایی آن‌ها در اعتبارسنجی مشتریان مشخص شد. نتایج حاکی از آن است که بر اساس هر دو معیار صحت (نرخ موفقیت) و سنجه  $F$  (میانگین هارمونیک بین دقت و یادآوری) مدل ترکیبی فرایادگیر (DL)-(DBSCAN)-(KNN-NN-SVMPSO) با نرخ صحت ۹۹٫۹۰٪ از بالاترین عملکرد نسبت به سایر مدل‌های پایه و ترکیبی فرایادگیر برخوردار است. همچنین با استفاده از روش‌های تجزیه و تحلیل اصل جزء (PCA)، شاخص جینی (Gini)، نسبت اطلاعات بهره (IGR) و اطلاعات بهره (IG) نسبت به محاسبه وزن ویژگی‌ها و رتبه میانگین آن‌ها نشان داده شد، که ویژگی‌هایی همچون میزان وثیقه، نوع وثیقه و میزان تسهیلات به ترتیب مهم‌ترین ویژگی‌ها در تشخیص مشتریان خوب (دارای ریسک اعتباری کم) از بد (دارای ریسک اعتباری بالا) بوده‌اند.

کلیدواژه‌ها: ریسک اعتباری؛ یادگیری ماشین؛ مشتری خوب؛ مشتری بد.

تاریخ دریافت مقاله: ۱۴۰۰/۰۶/۲۷، تاریخ پذیرش مقاله: ۱۴۰۰/۰۸/۱۹.

\* دانشجوی دکتری مدیریت مالی، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران.

E-Mail: alghasemy@yahoo.com

\*\* دانشیار، گروه مدیریت، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران (نویسنده مسئول).

E-Mail: mir.fallahshams@iauctb.ac.ir

\*\*\* دانشیار، گروه مدیریت، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

## ۱. مقدمه

بانک‌ها همچون هر کسب و کار دیگری در طول حیات خود با ریسک‌های زیادی مواجه می‌شوند. یکی از مهم‌ترین این ریسک‌ها، ریسک اعتباری است که می‌تواند منجر به ورشکستگی بانک شده و به دلیل وجود مساله سرایت ریسک در شبکه بانکی در نهایت منجر به ایجاد اختلال در نظام پولی کشور شود. برای مهار ریسک اعتباری، عملیات اعتبارسنجی به عنوان یک روش موثر به شناخت مشتریان خوب و بد پرداخته و با این کار می‌تواند ریسک اعتباری آن‌ها را تعیین کند. مدل‌های زیادی برای سنجش ریسک اعتباری مشتریان ارائه شده‌است. این مدل‌ها در ابتدا به صورت قضاوتی بودند اما در طول زمان به سمت روش‌های ناپارامتریک و پارامتریک گرایش یافته‌اند. برخی از بانک‌ها در سال ۱۹۴۱ با تفکیک مشتریان به دو گروه خوب و بد به اعطای وام به آن‌ها می‌پرداختند. کارت‌های اعتباری در سال ۱۹۶۰ وارد بانک‌ها شدند. در سال ۱۹۸۰ برای اولین بار از اعتبارسنجی در بانک‌ها استفاده شد. همچنین اعتبارسنجی در بازاریابی مستقیم در سال ۱۹۹۰ به کار رفت. نتایج ملموس و مناسب به کارگیری اعتبارسنجی مشتریان برای بانک‌ها در طول زمان، منجر به استفاده فراوان از این تکنیک‌ها در شبکه بانکی شده‌است [۱۹].

داده‌کاوی<sup>۱</sup> حوزه‌ای جدید، میان‌رشته‌ای و در حال رشد است که حوزه‌های مختلفی همچون پایگاه داده، آمار، یادگیری ماشین و سایر زمینه‌های مرتبط را با هم تلفیق کرده تا اطلاعات و دانش ارزشمند نهفته در حجم بزرگی از داده‌ها را استخراج کند. حجم زیاد داده‌های موجود در شبکه بانکی و توانایی‌های داده‌کاوی در یافتن الگوهای مناسب در پایگاه‌های داده، منجر به استفاده از این روش در سنجش اعتبار مشتریان شده است. مهم‌ترین و زمانبرترین مرحله در پروژه‌های داده‌کاوی اعتباری، مرحله آماده‌سازی و مرتب‌کردن داده‌ها است. علت این مساله وجود بسیاری از داده‌های مبهم و مغشوش و یا داده‌هایی با کلاس نامتوازن است.

تفکیک مشتریان کم‌ریسک از پرریسک و همچنین رتبه‌بندی آن‌ها باعث افزایش قدرت تصمیم‌گیری مدیران بانک‌ها خواهد شد. رتبه‌بندی مشتریان بر اساس ریسک اعتباری امکان تصمیمات مناسب‌تر در اعطای وام را برای مشتریان بانک مهیا کرده و می‌تواند نسبت تسهیلات غیرجاری به کل تسهیلات بانک‌ها را کاهش دهد. به این معنی که میزان مطالبات مشکوک‌الوصول بانک کاهش یافته و ریسک ورشکستگی کاهش می‌یابد. اعتبارسنجی مشتریان در ایران بسیار ضروری است چراکه متاسفانه بانک‌های تجاری در ایران امکان شناسایی دارایی‌های موهوم را دارند. با بررسی پیشینه عملکرد بانک‌ها در ایران مشخص شد که در صورت نکول مشتریان بانک‌ها با استمهال کردن قرارداد وام و یا تجدید قرارداد وام سودهایی موهومی خلق می‌کنند. به همین دلیل ارزش واقعی سمت راست و چپ ترازنامه بانک‌ها با یکدیگر برابر

<sup>۱</sup> Data Mining

نیست. این مساله در بلند مدت منجر به بحران بانکی و به دلیل نقش بسیار مهم بانک‌ها در نظام پولی منجر به بحران اقتصادی و سایر بحران‌هایی چون ارزی و ... خواهد شد. لذا در پژوهش حاضر با توجه به گستره استفاده از رویکردهای داده‌کاوی و یادگیری ماشین در مقالات علمی و همچنین در بخش‌های مختلف تجاری نظیر تحلیل و مدیریت بازار، بازاریابی و مدیریت ریسک، و لزوم هماهنگی بیشتر سنج‌های مالی و اقتصادی کشور با تحولات روز دنیا، و در جهت مرتفع نمودن یکی از مشکلات رایج بانک‌ها که همانا ریسک اعتباری است، از الگوها و مدل‌های یادگیری ماشین و استخراج دانش از پایگاه داده‌های مشتریان برای سنجش ریسک اعتباری مشتریان استفاده خواهد شد.

بررسی پیشینه ریسک اعتباری و اعتبارسنجی بانک‌ها نشان می‌دهد که تاکنون تحقیق جامعی در حوزه اثربخشی مدل‌های داده‌کاوی و یادگیری ماشین در ایران انجام نشده و بیشتر مقالات با یک مدل یا روش به بررسی موضوع پرداخته‌اند. بنابراین وجه تمایز پژوهش حاضر یکی استفاده از روش‌های یادگیری ماشین و دیگری رویکرد جامع در مقایسه روش‌های سنجش ریسک اعتباری مشتریان است.

در نخستین مرحله از پژوهش حاضر با مرور ادبیات موضوع، شاخص‌های مهم و مؤثر در ارزیابی ریسک اعتباری مشتریان بر مبنای مدل C6<sup>۱</sup> شناسایی و طبقه‌بندی شده و به عنوان مبنای مدل‌سازی ماشینی قرار خواهند گرفت.

## ۲. مبانی نظری و پیشینه پژوهش

### ریسک اعتباری

با وجود تلاش‌های فراوان در تعریف ریسک، اقتصاددانان همچنان به مفهومی جامع و واحدی از این واژه دست نیافته‌اند. اما به‌طور کلی یک مفهوم مشترک را می‌توان در بین تعاریف ارائه‌شده مشاهده کرد: عمل یا اقدامی که بیش از یک نتیجه دارد و تا زمان محقق شدن نتایج از حصول هیچ‌یک از نتایج اطمینانی وجود ندارد و حداقل یکی از نتایج ممکن پیامد نامطلوبی به همراه دارد. با وجود ریسک‌های متعدد و طبقه‌بندی‌های مختلف در نظام بانکی، برخی ریسک‌ها از نظر ناظران بین‌المللی، از جمله کمیته بال، مستلزم توجه خاصی بوده و در کشور ایران نیز مورد توجه زیاد قرار گرفته‌است. این ریسک‌ها عبارت‌اند از: ریسک اعتباری، ریسک نقدینگی، ریسک عملیاتی و ریسک بازار. در شبکه بانکی ریسک اعتباری از منظر شدت احتمال و قدمت در مقایسه با سایر ریسک‌ها در اولویت است. ریسک اعتباری ریسکی است که از نُکول/قصور وام‌گیرنده به‌وجود می‌آید. به همین سبب، گاهی اوقات ریسک اعتباری را «ریسک نکول» نیز

<sup>۱</sup> این مدل شامل ۶ عامل شخصیت، ظرفیت و قدرت، سرمایه، شرایط، وثیقه و شرایط و ضوابط تسهیلات است.

می‌گویند [۱۳]. ریسک اعتباری اصلی‌ترین عامل ورشکستگی بانک‌ها محسوب می‌شود و تمرکز اعطای تسهیلات با حجم بالا به افراد حقیقی و حقوقی از عوامل افزایش‌دهنده این ریسک است [۱۵]. بانک برای بقای خود و جلوگیری از ورشکستگی نیازمند یک سیستم مدیریت ریسک جامع است تا قادر باشد زیان ناشی از عملیات بانکی را پیش‌بینی و بموقع از آن جلوگیری کند. یکی از ابزارهای مدیریت ریسک اعتباری سیستم رتبه‌بندی و امتیازدهی اعتباری است که به منظور تعیین درجه ریسک متقاضیان تسهیلات اعتباری به‌کار می‌رود و به بانک‌ها در شناسایی مشتریان خوش‌حساب و بدحساب کمک می‌کند. الگوهای مختلفی برای رتبه‌بندی و امتیازدهی اعتباری ارائه شده است از جمله این الگوها می‌توان به رگرسیون لجستیک، تحلیل ممیزی و شبکه‌های عصبی اشاره کرد [۲۰].

### روش‌ها و مدل‌های یادگیری ماشین

روش‌های یادگیری ماشین، سیستم‌های مختلف را قادر به یادگیری، استنتاج و ارائه پیشنهادها کاربردی می‌کند. این سیستم‌ها در طول زمان در اثر تعامل با داده‌ها، ادوات، شبکه‌ها و افراد مختلف باهوش‌تر می‌شوند. با استفاده از رویکردهای یادگیری ماشین و هوش مصنوعی، این سیستم‌ها قادر هستند ما را در حل مسائل مهم، کاربردی و روزمره یاری دهند. غالباً این کار، با استناد و با استفاده از داده‌هایی انجام می‌شود که به دلیل حجم زیاد و یا ماهیت نامفهوم، برای انسان‌ها چندان قابل استفاده نیست. روش‌ها و الگوریتم‌های یادگیری ماشین را می‌توان به سه گروه اصلی تقسیم کرد: نظارتی، غیرنظارتی و تقویت‌شده.

### یادگیری نظارت شده

در این نوع از الگوریتم‌ها که بار اصلی یادگیری ماشین را بر دوش می‌کشند (از لحاظ تعداد الگوریتم‌های این نوع)، دو نوع متغیر وجود دارد. نوع اول که متغیرهای مستقل نامیده می‌شوند، یک یا چند متغیر هستند که قرار است بر اساس مقادیر آن‌ها، یک متغیر دیگر پیش‌بینی شود. نوع دوم متغیرهای وابسته یا هدف یا خروجی هستند و قرار است مقادیر آن‌ها به کمک این الگوریتم‌ها پیش‌بینی شود. برای این منظور باید تابعی ایجاد شود که ورودی‌ها (متغیرهای مستقل) را گرفته و خروجی موردنظر (متغیر وابسته یا هدف) را تولید کند. فرایند یافتن این تابع که در حقیقت کشف رابطه‌ای بین متغیرهای مستقل و متغیرهای وابسته است را فرآیند آموزش می‌گویند که روی داده‌های موجود (داده‌هایی که هم متغیرهای مستقل و هم متغیرهای وابسته آن‌ها معلوم هستند) اعمال می‌شود و تا رسیدن به دقت لازم ادامه می‌یابد. نمونه‌هایی از این الگوریتم‌ها عبارتند از رگرسیون، درخت‌های تصمیم، جنگل‌های تصادفی و نزدیک‌ترین همسایه.

### یادگیری نظارت‌نشده

در این نوع از الگوریتم‌ها، متغیر هدف وجود نداشته و خروجی الگوریتم، نامشخص است. بهترین مثالی که برای این نوع از الگوریتم‌ها می‌توان زد، گروه‌بندی خودکار (خوشه‌بندی) یک جمعیت است. برای مثال در یک بانک با داشتن اطلاعات شخصی و ویژگی‌های تسهیلات، مشتریان به گروه‌های همسان و هم‌ارز تقسیم می‌شوند. الگوریتم‌های Apriori و K-Means از این دسته هستند.

### یادگیری تقویت‌شده

نوع سوم از الگوریتم‌ها که شاید بتوان آن‌ها را در زمره الگوریتم‌های بدون ناظر هم دسته‌بندی کرد، دسته‌ای هستند که از آن‌ها با نام یادگیری تقویت‌شونده یاد می‌شود. در این نوع از الگوریتم‌ها، یک ماشین (در حقیقت برنامه کنترل‌کننده آن)، برای گرفتن یک تصمیم خاص، آموزش داده‌می‌شود و ماشین بر اساس موقعیت فعلی (مجموعه متغیرهای موجود) و اقدامات مجاز (مثلاً حرکت به جلو، حرکت به عقب و ...)، یک تصمیم را اتخاذ می‌کند. این تصمیم در دفعات اول می‌تواند کاملاً تصادفی باشد. به ازای هر اقدام یا رفتاری که بروز می‌دهد، بازخورد یا امتیاز به تصمیم گرفته‌شده داده‌می‌شود و از روی این بازخورد، ماشین متوجه می‌شود که تصمیم درست را اتخاذ کرده است یا خیر. بر اساس نتیجه سیستم متوجه می‌شود که اگر در آینده در همان موقعیت قرار گرفت، همان اقدام قبلی را تکرار کند یا اقدام و رفتار دیگری را امتحان کند. با توجه به وابسته بودن حالت و رفتار فعلی سیستم به حالات و رفتارهای قبلی، فرآیند تصمیم‌گیری مارکوف، می‌تواند یکی از مثال‌های این گروه از الگوریتم‌ها باشد. الگوریتم‌های شبکه‌های عصبی هم می‌توانند از این دسته به حساب آیند. منظور از کلمه تقویت‌شونده در نام‌گذاری این الگوریتم‌ها اشاره به مرحله بازخورد دارد که باعث تقویت و بهبود عملکرد برنامه و الگوریتم می‌شود. اگر کامپیوتر تنها یک یا دو بار تصمیم بگیرد و بازخورد دریافت کند عملکردی قابل اتکا نخواهد داشت. اما اگر هزاران بار و حتی میلیون‌ها بار تصمیم بگیرد و بازخورد دریافت کند، نوعی استراتژی قابل اتکا شکل می‌گیرد.

برای تفکیک مشتریان به مشتریان خوب و بد، اشراف به روش‌های طبقه‌بندی ضرورت می‌یابد. لذا در این قسمت، الگوریتم‌هایی که برای طبقه‌بندی در این مطالعه مورد استفاده قرار می‌گیرند تشریح خواهند شد.

## درخت تصمیم<sup>۱</sup>

درختان تصمیم‌گیری می‌توانند با شناسایی ویژگی‌های مشتریان و تفکیک آن‌ها به گروه‌های خوب و بد، به اعتبارسنجی آن‌ها بپردازند. این الگوریتم مبتنی بر ساختار درخت می‌باشد و مزیت اصلی آن الگوهای تصمیم‌گیری‌ای هستند که به راحتی برای انسان قابل فهم می‌باشند [۲۱]. مشکل اصلی در درختان تصمیم‌گیری، پیچیدگی، اندازه بیش از حد، عدم انعطاف‌پذیری و دقت کم در طبقه‌بندی است. از طرف دیگر با توجه به اینکه الگوریتم درخت تصمیم‌گیری C4.5 یک الگوریتم بازگشتی و حریصانه است، منجر به ایجاد درخت تصمیم‌گیری پیچیده و بزرگ می‌شود. به همین دلیل قسمت‌های پایینی درخت تعداد کمی تراکنش را پوشش می‌دهند. تعداد کم تراکنش در قسمت‌های پایینی درخت اگرچه منجر به افزایش دقت درخت در طبقه‌بندی مشتریان می‌شود ولی از طرف دیگر انعطاف‌پذیری را در طبقه‌بندی مشتریان کاهش داده و تنها با تغییری کوچک کلاس یا طبقه یک مشتری جدید تغییر می‌کند. به همین دلیل به نظر می‌رسد اگر بتوان تا جایی که لطمه‌ای به دقت طبقه‌بندی در درخت تصمیم‌گیری وارد نشود، اندازه درخت، تعداد برگ‌ها و در نتیجه پیچیدگی درخت تصمیم‌گیری را کاهش داد، علاوه بر افزایش انعطاف‌پذیری در طبقه‌بندی، کاهش اندازه درخت و پیچیدگی آن می‌تواند طبقه‌بندی بهتری را برای مشتریان بانک انجام داد [۱].

## شبکه‌های عصبی مصنوعی<sup>۲</sup>

شبکه‌های عصبی مصنوعی یا همان شبکه‌های عصبی مشتمل بر گروهی از گره‌های عصبی هستند که از طریق گره‌های وزنی با هم در ارتباط هستند. هر گره نقش یک نرون عصبی جاندار را بازی می‌کند. رایج‌ترین نوع این شبکه‌های مصنوعی شامل سه لایه ورودی، پنهان و خروجی هستند [۹].

## بیزین ساده<sup>۳</sup>

این روش طبقه‌بندی بر اساس تئوری بیز است که از تمامی احتمالات پیشین و احتمالات قابل مشاهده در جامعه آماری استفاده می‌کند تا بتواند احتمالات آینده را پیش‌بینی کند. این روش ابزاری کارآمد برای پیش‌بینی روابط اعضای یک طبقه در یک موقعیت نامشخص است. این مدل طبقه‌بندی نیازمند این است که تمامی فرضیات به‌صورت مشخصی در مدل اعمال گردند که در این صورت بعداً در رسیدن به تصمیم بهینه و یا الگوی طبقه‌بندی استفاده خواهد شد. این مدل برای نشان‌دادن وابستگی بین متغیرهای تصادفی (ویژگی‌ها) قابل استفاده است. این مدل

<sup>۱</sup>Decision Tree

<sup>۲</sup>Artificial Neural Network

<sup>۳</sup>Naïve Bayesian

با استفاده از داده‌های آموزش دیده می‌تواند احتمال اینکه هر مشاهده با در نظر گرفتن ویژگی‌هایش در کدام طبقه قرار می‌گیرد را تخمین بزند [۵].

### رگرسیون لوجستیک<sup>۱</sup>

رگرسیون لوجستیک یک روش آماری پارامتریک محسوب می‌شود. این روش شباهت زیادی به رگرسیون‌های مرسوم دارد بدین معنی که شروط مربوط به تحلیل خطی مانند عدم وجود خودهمبستگی در پسماندها، عدم وجود همخطی چندگانه بین متغیرهای مستقل و توزیع نرمال در بین داده‌های دریافتی می‌بایست رعایت شوند [۱۰]. رگرسیون لوجستیک برای مدل‌سازی پارامترهایی که قابلیت طبقه‌بندی و تفکیک مشاهدات را دارند، از یک سری محاسبات عددی استفاده می‌کند. این رگرسیون همانند تحلیل تفکیکی می‌باشد که رابطه بین متغیرهای مستقل و وابسته را بررسی می‌کند. تفاوت بین آنالیز تفکیکی و رگرسیون لوجستیک این هست که آنالیز تفکیکی می‌بایست شروط توزیع نرمال و ماتریس‌های کواریانس مساوی را به منظور پیدا کردن مقدار بهینه برآورده کند. درحالی‌که رگرسیون لوجستیک به این شروط احتیاجی ندارد اما اگر این شروط برآورده شوند، رگرسیون لوجستیک می‌تواند به دقت بالاتری در پیش بینی دست یابد.

### نزدیک‌ترین همسایه‌ها<sup>۲</sup>

الگوریتم نزدیک‌ترین همسایه‌ها یک الگوریتم نظارت‌شده آماری است که در تشخیص الگو کاربرد دارد. این الگوریتم از قدرت عملکردی بالایی برخوردار بوده و برای توزیع آماری مشاهداتی که برای آموزش فراخوانی شده‌اند، توزیع خاصی را الزام نمی‌کند. آموزش بر اساس مشاهدات شامل هر دو نوع مشاهدات منفی و مثبت می‌شود. یک نمونه آماری جدید بر مبنای محاسبه فاصله تا نزدیک‌ترین مورد آموزشی طبقه‌بندی می‌شود [۱۷]. این الگوریتم طبقه‌بندی تعداد  $k$  عدد از نزدیک‌ترین نقاط (مشاهده) را انتخاب کرده و علامت اکثریت را به آن نسبت می‌دهد. مقدار  $k$  معمولاً بین ۱ تا ۵ انتخاب می‌شود. مقادیر بزرگ‌تر می‌تواند به کاهش اثر مشاهدات مزاحم کمک کند. بهینه‌ترین مقدار  $k$  معمولاً از طریق روش اعتبار سنجی متقابل<sup>۳</sup> انتخاب می‌گردد.

### ماشین بردار پشتیبان<sup>۴</sup>

رویکرد SVM به این صورت است که در مرحله آموزش، سعی دارد مرز تصمیم‌گیری را به گونه‌ای انتخاب نماید که حداقل فاصله آن با هر یک از دسته‌های مورد نظر بیشینه باشد. این

<sup>۱</sup>Logistic Regression

<sup>۲</sup>K-nearest Neighbor

<sup>۳</sup>Cross-validation

<sup>۴</sup>Support Vector Machines



نوع انتخاب باعث می‌شود که تصمیم‌گیری در عمل، شرایط نویزی را به‌خوبی تحمل نموده و پاسخ‌دهی مناسبی داشته باشد. این نحوه انتخاب مرز بر اساس نقاطی به نام بردارهای پشتیبان انجام می‌شود.

الگوریتم‌های مبتنی بر ماشین‌های بردار پشتیبان الگوریتم‌هایی هستند که سعی می‌کنند یک حاشیه را بیشینه کنند. این الگوریتم‌ها برای پیدا کردن خط جداکننده دسته‌ها از دو خط موازی شروع کرده و این خطوط را در خلاف جهت یکدیگر حرکت می‌دهند تا هر کدام از خطوط بهینه به یک نمونه از یک دسته خاص در سمت خود برسد. پس از انجام این مرحله، میان دو خط موازی یک نوار یا حاشیه شکل می‌گیرد. هر چه پهنای این نوار بیش‌تر باشد، به این معناست که الگوریتم توانسته‌است حاشیه را بیشینه کند و هدف نیز بیشینه‌نمودن این حاشیه است.

#### ماشین بردار پشتیبان بهینه شده با الگوریتم ازدحام ذرات<sup>۲</sup>

سابقه استفاده از ماشین‌های بردار پشتیبان در ادبیات یادگیری ماشین بسیار است. برخی از محققان برای بهبود کارایی این الگوریتم آن‌را با الگوریتم‌های دیگری ترکیب کرده‌اند. یکی از این فرایندهای بهینه‌سازی با استفاده از الگوریتم ازدحام ذرات<sup>۳</sup> انجام می‌شود [۲۴]. همان‌طور که پیش‌تر توضیح داده شد، وظیفه یک ماشین بردار پشتیبان انتخاب یک مرز تصمیم‌گیری است که فاصله آن با هر یک از دسته‌های مورد نظر بیشینه باشد. بنابراین برای بهینه کردن خط جداکننده دسته‌ها می‌توان از الگوریتم بهینه‌سازی ازدحام ذرات استفاده کرد. این الگوریتم که توسط کندی و ابرهارت (۱۹۹۵) و کندی و همکاران (۲۰۰۱) ارائه شده است، مبتنی بر تکنیک بهینه‌کردن تصادفی جمعیت محور بوده که از روی شبیه‌سازی رفتار پرندگان الهام گرفته شده‌است [۱۱، ۶].

#### پرسپترون چندلایه خودکار<sup>۴</sup>

الگوریتم پرسپترون چندلایه خودکار (AMLP) یکی از انواع شبکه‌های عصبی مصنوعی بوده و به‌طور معمول از سه لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده‌است که به ترتیب اطلاعات را دریافت، پردازش و نمایش می‌دهند. AMLP الگوریتمی است که برای نرخ یادگیری و تنظیم مقدار شبکه‌های عصبی مصنوعی در خلال آموزش به‌کار می‌رود. این الگوریتم از ترکیب ایده الگوریتم ژنتیک و بهینه‌سازی تصادفی پدید آمده‌است. AMLP از گروه کوچکی از شبکه‌ها که با نرخ و شمار لایه‌های پنهان متفاوت آموزش دیده‌اند را ذخیره می‌کند. بعد از تعداد دورهای مشخص آموزش، نرخ خطا در نمونه آزمودنی اندازه‌گیری می‌شود و بدترین

<sup>۱</sup>Hyperplane

<sup>۲</sup>SVM-PSO

<sup>۳</sup>Particle Swarm Optimization

<sup>۴</sup>Automated Multilayer Perceptron

شبکه‌های عصبی با بهترین‌ها تعویض می‌شوند. تعداد لایه‌های پنهان و نرخ‌های یادگیری بر حسب توزیع احتمال بهترین و موفق‌ترین مدل انتخاب می‌شوند [۳].

### خوشه‌بندی

خوشه‌بندی داده، یکی از رایج‌ترین تکنیک‌های داده‌کاوی است. تجزیه و تحلیل خوشه‌ای روشی برای گروه‌بندی داده‌ها یا مشاهدات، با توجه به شباهت یا درجه نزدیکی آن‌ها است. از طریق تجزیه و تحلیل خوشه‌ای، داده‌ها یا مشاهدات به دسته‌های همگن و متمایز از هم تقسیم می‌شوند. در روش خوشه‌بندی هیچ دسته‌ای از قبل وجود ندارد و در واقع متغیرها به صورت مستقل و وابسته تقسیم نمی‌شوند و مبنای شناسایی بهتر رفتارها در روش خوشه‌بندی میزان شباهت است.

روش خوشه‌بندی یک روش غیرمستقیم است. بدین معنی که این روش را می‌توان حتی هنگامی که هیچ نوع اطلاعات قبلی از ساختار پایگاه داده وجود ندارد نیز استفاده نمود. از این روش می‌توان برای کشف الگوهای پنهان و بهبود عملکرد روش‌های مستقیم نیز استفاده نمود. یکی از نقاط ضعف این روش این است که انتخاب اندازه‌های دقیق فواصل و وزن‌ها کار آسانی نیست و به پارامترهای اولیه نظیر تعداد خوشه‌ها، حداقل نزدیکی و خوشه‌های اولیه حساس است. تفسیر نتایج این روش می‌تواند مشکل باشد و معمولاً به تحلیل افراد خبره نیاز دارد. مراحل تجزیه و تحلیل خوشه‌ای عبارت است از: انتخاب معیار شباهت یا نزدیکی مشاهدات، انتخاب روش تجزیه و تحلیل، تصمیم‌گیری در مورد تعداد خوشه‌ها و تفسیر دسته‌ها یا گروه‌های تشکیل شده.

### روش‌های یادگیری ماشین هیبریدی

مدل‌های هیبریدی با ترکیب تکنیک‌های مختلف یادگیری ماشین، شکل گرفته‌اند که نتایج حاصل از آن‌ها نسبت به استفاده منفرد از تکنیک‌ها بهتر بوده است. روش و انواع مختلفی از ترکیب برای ایجاد مدل‌های هیبریدی وجود دارد و به طور قطع نمی‌توان گفت که کدام ترکیب از مدل هیبریدی یادگیری ماشین می‌تواند بر روی یک مجموعه داده نتایج بهتری برای رتبه‌بندی اعتباری و اعتبارسنجی ایجاد نماید. به عنوان مثال در مقاله رتبه‌بندی اعتباری با تکنیک‌های یادگیری ماشین هیبریدی که توسط تسای و چن (۲۰۱۰) ارائه شده، چهار نوع مختلف از مدل‌های هیبریدی زیر مورد ارزیابی قرار گرفته است [۲۱]:

- Classification + Classification
- Classification + Clustering
- Clustering + Classification
- Clustering + Clustering

این مدل‌های ترکیبی بر روی داده‌های بانک در تایوان پیاده شد و نتایج آن نشان می‌دهد که مدل هیبریدی Classification + Classification مبتنی بر ترکیب رگرسیون لوجستیک و شبکه‌های عصبی دقت بالایی را ایجاد می‌کند [۲۱]. به طور کلی مدل‌های هیبریدی بر مبنای ترکیب تکنیک‌های طبقه‌بندی و خوشه‌بندی استوار است.

#### پیشینه پژوهش

در این بخش به تعدادی از مهم‌ترین مقالاتی داخلی و خارجی در حوزه ریسک اعتباری اشاره خواهد شد:

میسمان و بهاتی (۲۰۲۰) به بررسی مسائل مهم مربوط به ریسک اعتباری در بانک‌های منتخب اسلامی در نه کشور جنوب شرق آسیا (ASEAN) و شورای همکاری خلیج فارس (GCC) پرداخته و برای تعیین ریسک اعتباری هر بانک با استفاده از رگرسیون داده‌های پانل، نسبت تامین مالی غیرجاری به کل تامین مالی هر بانک را با سایر متغیرهای خاص بانک‌ها (BSV) مورد بررسی قرار دادند. این پژوهش از ۱۲ سال داده‌های پانل از ۴۰ بانک مختلف اسلامی استفاده می‌کند. یافته‌های این محققان نشان می‌دهد که کیفیت تامین مالی، تأثیر مثبت قابل توجهی بر ریسک اعتباری دارد و بانک‌های بزرگ‌تر ریسک اعتباری کمتری در مقایسه با بانک‌های کوچک‌تر دارند. این محققان به سن بانک نیز به عنوان عاملی مهم و تاثیرگذار بر سطح ریسک اعتباری بانک‌ها اشاره می‌کنند [۱۴].

گیودیسی، هادجی میثوا و اسپلتا (۲۰۲۰) مدلی را برای بهبود دقت ریسک اعتباری در بسترهای مشابه و به ویژه بانک‌هایی که به شرکت‌های کوچک و متوسط وام می‌دهند، ارائه می‌دهند. این محققان روش‌های سنتی رتبه‌بندی اعتباری را با استفاده از «داده‌های جایگزین» که شامل معیارهای مرکزیت مشتق شده از شبکه‌های مشابه بین وام گیرندگان است (استخراج شده از نسبت‌های مالی آن‌ها)، افزایش می‌دهند. یافته‌های تجربی آن‌ها نشان می‌دهد که رویکرد پیشنهادی، دقت پیش بینی و همچنین توضیح مدل را بهبود می‌بخشد [۸].

عمر، میرزا و نقوی (۲۰۲۱) تاثیر وام دهی کشورهای بدون کربن بر ریسک اعتباری در منطقه یورو را ارزیابی می‌کنند. این محققان بر اساس داده‌های فصلی نمونه ای از ۳۴۴ موسسه مالی از ۱۹ کشور عضو اتحادیه اروپا در طول ده سال از ۲۰۱۱ تا ۲۰۲۰ و با استفاده از دو معیار ریسک اعتباری نشان می‌دهند که قرار گرفتن در معرض وام های بدون کربن رابطه‌ای منفی با ریسک دارد. نتایج آن‌ها نشان می‌دهد که صرف نظر از اندازه بانک، تأثیر تأمین مالی سبز بر ریسک اعتباری یکسان است [۲۲].

ادو، گوگان و حسنی (۲۰۱۸) با استفاده از طبقه‌بندی‌کننده‌های دوتایی و بر اساس مدل‌های ماشین و یادگیری عمیق نشان دادند که مدل‌های مبتنی بر درخت از مدل‌های مبتنی بر شبکه‌های عصبی مصنوعی چند لایه پایدارتر هستند [۲].

نیلچی و همکاران (۲۰۱۹) در پژوهش خود پس از گزینش شاخص‌های اساسی شکل‌دهنده رفتار مشتریان، به کمک روش نمونه‌گیری طبقه‌بندی شده، ۵۲۱ نمونه تصادفی از بین پرونده‌های تسهیلاتی مشتریان صاحبان کسب‌وکار متقاضی تسهیلات را بررسی نموده و ۸۵ شاخص جهت مدل‌سازی انتخاب و به‌منظور سنجش درجه اهمیت عوامل موثر بر رفتار اعتباری متقاضیان، از الگوریتم‌های درخت تصمیم، شبکه عصبی و ماشین بردار پشتیبان بهره گرفته‌اند که الگوریتم درخت تصمیم با میانگین قدر مطلق خطای ۱۴ درصد در بهترین حالت نرخ نکول را پیش‌بینی نموده است. براساس نتایج پژوهش این محققان استفاده از شاخص‌های موثر شناسایی شده می‌تواند نقش حائز اهمیتی در تصمیم‌گیری و پیش‌بینی رفتار اعتباری مشتری داشته باشد [۱۶].

تهرانی و فلاح شمسی (۲۰۰۵) کارایی مدل‌های احتمالی خطی، لجستیک و شبکه‌های عصبی مصنوعی را برای پیش‌بینی ریسک اعتباری مشتریان نظام بانکی کشور مورد بررسی قرار داده‌اند. متغیرهای پیش‌بینی‌کننده در این مدل‌ها، نسبت‌های مالی تسهیلات گیرندگان بوده که در این پژوهش ارتباط معنادار آن‌ها با ریسک اعتباری تایید شده‌است. این محققان با استفاده از داده‌های مالی و اعتباری ۳۱۶ نفر از مشتریان حقوقی بانک‌های کشور، کارایی مدل‌های خود را بررسی کردند. نتایج پژوهش آن‌ها بیانگر آن است که ارتباط بین متغیرها در مدل پیش‌بینی ریسک اعتباری به صورت خطی نبوده و تابع‌های نمایی و سیگموئید، مناسب‌ترین مدل‌های پیش‌بینی ریسک اعتباری محسوب می‌شوند و بیشترین کارایی برای پیش‌بینی ریسک اعتباری به ترتیب مربوط به شبکه‌های عصبی و مدل لجستیک است [۱۸].

دادمحمدی و احمدی (۲۰۱۵) با استفاده از شبکه‌های عصبی توانمند در حوزه پیش‌بینی، به تهیه و تدوین مدلی به منظور رتبه‌بندی اعتباری مشتریان بانک پرداخت. مدل پیشنهادی آن‌ها دارای ساختار همزمان رو به جلو و جانبی است که شبکه عصبی با اتصالات جانبی نام دارد. نتایج حاصل از این شبکه با شبکه عصبی با تابع فعال‌سازی شعاعی و شبکه یادگیری کوانتیزه نمودن برداری، در قالب دو مجموعه آموزش و تست مقایسه شده است. مدل پیشنهادی به دلیل توانایی بالا در پیش‌بینی مجموعه تست داده‌های مشتریان و همچنین نرخ خطای بسیار کم در مقایسه با دو مدل دیگر، به عنوان مدل برتر انتخاب شد. بنابراین با طراحی یک شبکه عصبی جدید و قدرتمند و نیز انتخاب دقیق نسبت‌های مالی تاثیرگذار در نظام رتبه‌بندی اعتباری، مدل پیشنهادی توانست رفتار مشتریان را با دقت بسیار بالایی در دو گروه خوش حساب و بدحساب پیش‌بینی کند [۴].

خوانساری و فلاح شمس (۲۰۱۰) به پیش‌بینی ورشکستگی مشتریان حقوقی بانک‌های ایرانی پرداختند. داده‌های تحقیق آن‌ها از نمونه‌ای شامل ۴۰ شرکت سهامی دریافت‌کننده تسهیلات از بانک‌های ایرانی طی سال‌های ۱۳۸۶ و ۱۳۸۷ استخراج شده‌است. نتایج این تحقیق نشان داد که مدل KMV قابلیت پیش‌بینی نکول و تفکیک بین مشتریان خوش‌حساب و بدحساب را دارد و می‌توان از آن به منظور پیش‌بینی نکول مشتریان حقوقی دریافت‌کننده تسهیلات از بانک‌های ایرانی استفاده کرد [۱۲].

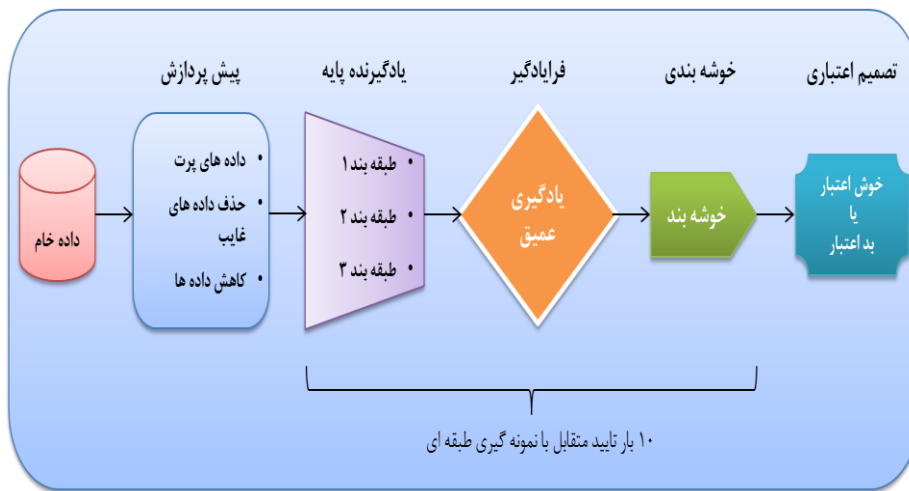
خی‌یو (۲۰۰۶) در پژوهشی در خصوص ساختار رتبه بندی اعتباری، از روش‌های درخت تصمیم، شبکه عصبی و رگرسیون لجستیک در ساخت مدل داده‌کاوی استفاده کردند و نتایج بدست آمده از تحقیقات حاکی از آن است که تلفیق مدل‌ها نتایج بهتری را نسبت به نتایج فردی هر یک از مدل‌ها در بر خواهد داشت [۲۳].

قاسمی و دنیایی هریس (۲۰۱۶) از تکنیک تلفیقی MADM و SOM استفاده کرده و مدلی برای رتبه بندی مشتریان در حوزه ریسک اعتباری طراحی کردند. نتایج پژوهش آن‌ها حاکی از عملکرد مناسب مدل ارائه شده است [۷].

دومپاس و زورپونیدیس (۲۰۱۳) با استفاده از روش Promethee2 به رتبه‌بندی بانک‌ها براساس معیارهای مدیریت ریسک مالی پرداختند آن‌ها علت استفاده از این روش را توانایی بررسی جزئیات بیشتر گزینه‌ها در مقایسه با یکدیگر عنوان نمودند [۲۵].

### ۳. روش‌شناسی پژوهش

یادگیری عمیق یک زیر شاخه از یادگیری ماشینی و بر مبنای مجموعه‌ای از الگوریتم‌ها است که در تلاش هستند مفاهیم انتزاعی سطح بالا در داده‌ها را تبدیل به مدل نمایند و این فرایند را با استفاده از یک گراف عمیق که دارای چندین لایه پردازشی متشکل از چندین لایه تبدیلات خطی و غیر خطی هستند، انجام می‌دهند. به عبارت دیگر پایه آن بر یادگیری نمایش دانش و ویژگی‌ها در لایه‌های مدل است. هر مرحله تکرار الگوریتم یادگیری عمیق یک پروسه یادگیری ویژگی غیر نظارت شده است که در مجموعه‌ای از لایه‌های مختلف می‌تواند منجر به تولید یک پیش‌بینی‌کننده نظارتی عمیق شود. شکل ۱ ساختار کلی مدل به‌کار گرفته‌شده در پژوهش حاضر را نمایش می‌دهد.



شکل ۱. چهارچوب کلی مدل فرایادگیر با کاربرد اعتبار سنجی

پس از بررسی ادبیات موضوع و تعریف پارامترها، داده‌های لازم بر اساس جدول متغیرها تهیه و با استفاده از الگوریتم‌های مختلف خوشه‌بندی می‌شوند. این خوشه‌بندی موجب شناخت بیشتر ساختار داده‌ای شده و در مدل‌سازی بهتر کمک خواهد کرد. داده‌های مدل مورد نظر در اکسل، و یا با نرم‌افزار ریپیدماینر<sup>۱</sup> بر اساس نیاز مدل‌سازی می‌شود. نرم‌افزار ریپیدماینر یک نرم‌افزار پیشرو و شناخته‌شده در حوزه داده‌کاوی و یادگیری ماشینی است که برتری‌هایی نسبت به رقبای خود همچون متلب<sup>۲</sup> و R دارد.

الگوریتم‌های مختلفی در حوزه یادگیری ماشین و هوش مصنوعی در سال‌های اخیر ایجاد یا بهبود یافته‌اند. پس از بررسی پیشینه مطالعات انجام گرفته در حوزه داده‌کاوی، بهترین الگوریتم‌هایی که توسط سایر محققان پیشین توصیه شده بود استخراج و در پژوهش حاضر مورد استفاده قرار می‌گیرد. این الگوریتم‌ها در جدول شماره ۱ معرفی شده که قابل تفکیک در سه رده الگوریتم‌های دسته‌بندی‌کننده<sup>۳</sup>، فرایادگیر<sup>۴</sup> و خوشه‌بند<sup>۵</sup> هستند.

<sup>۱</sup> RapidMiner

<sup>۲</sup> Matlab

<sup>۳</sup> classifiers

<sup>۴</sup> meta-learner

<sup>۵</sup> Clusterers

جدول ۱. تعریف الگوریتم های مورد کاربرد

شرح الگوریتم	مخفف
	الگوریتم های دسته بند:
پرسپترون چند لایه خودکار (Automated Multi-layer Perceptron)	AMLN
درخت تصمیم (Decision Tree)	DT
نزدیک ترین همسایه ها (K-nearest Neighbors)	KNN
ریگرسیون لجستیک (Logistic Regression)	LR
بیزین ساده (Naive Bayesian)	NB
شبکه های عصبی (Neural Network)	NN
ماشین بردار پشتیبان (Support Vector Machine)	SVM
ماشین بردار پشتیبان بهینه شده با الگوریتم ازدحام ذرات (Support Vector Optimization Machine optimized with Particle Swarm)	SVMPSO
	<b>الگوریتم فرایادگیر:</b>
یادگیری عمیق (Deep Learning)	DL
	<b>الگوریتم های خوشه بند:</b>
کی-میانگین (K-means)	KM
حداکثرسازی امید ریاضی (Expectation Maximization)	EM
سی-میانگین فازی (Fuzzy C-means)	FCM
خوشه بندی مکانی بر اساس چگالی در کاربردهای دارای نویز (Density-based Spatial Clustering of Applications with Noise)	DBSCAN
نگاشت خود سازمان ده (Self-organizing Map)	SOM

جدول شماره ۲ ماتریس سردرگمی برای مسئله اعتبار سنجی را نشان می دهد. در این تحقیق خوش حسابی کلاس منفی و بد حسابی کلاس مثبت در نظر گرفته شده است. هر یک از عناصر ماتریس به شرح ذیل می باشد:

TN: بیانگر تعداد رکوردهایی است که دسته واقعی آن ها منفی بوده و الگوریتم دسته بندی نیز دسته آن ها را به درستی منفی تشخیص داده است.

TP: بیانگر تعداد رکوردهایی است که دسته واقعی آن ها مثبت بوده و الگوریتم دسته بندی نیز دسته آن ها را به درستی مثبت تشخیص داده است.

FP: بیانگر تعداد رکوردهایی است که دسته واقعی آن ها منفی بوده و الگوریتم دسته بندی دسته آن ها را به اشتباه مثبت تشخیص داده است.

FN: بیانگر تعداد رکوردهایی است که دسته واقعی آن ها مثبت بوده و الگوریتم دسته بندی دسته آن ها را به اشتباه منفی تشخیص داده است.

جدول ۲. ماتریس سردرگمی برای مسئله اعتبار سنجی

بد حساب	خوش حساب	
FN	TN	پیش بینی شده به عنوان خوش حساب
TP	FP	پیش بینی شده به عنوان بد حساب

برای سنجش عملکرد مدل‌ها از معیارهای صحت، دقت، یادآوری<sup>۱</sup> و معیار F<sup>۲</sup> استفاده شده است. نحوه محاسبه این معیارها به صورت زیر است:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

**صحت:** میزان کل پیش بینی‌های درست نسبت به کل موارد.

$$\text{Precision} = \frac{TP}{TP + FP}$$

**دقت:** دقت سیستم در میان داده‌های پیش بینی شده است.

$$\text{Recall} = \frac{TP}{TP + FN}$$

**یادآوری:** نسبت تعداد داده‌های پیش شده، به تعداد کل داده‌های مورد انتظار برای پیش بینی است.

$$F - \text{measure} = \frac{2TP}{2TP + FP + FN}$$

**معیار F:** میانگین هارمونیک بین دقت و یادآوری است.

بر اساس پژوهش حاضر، کشف دانش از پایگاه داده‌های بانک مورد مطالعه و جامعه آماری آن پرونده‌های تسهیلاتی ۱۰۰۰۰ مشتریان حقیقی متقاضی تسهیلات بانک ملت از سال ۱۳۹۰ تا پایان سال ۱۳۹۵ است.

#### ۴. تحلیل داده‌ها و یافته‌ها

در این بخش از پژوهش در ابتدا به ارائه آمار توصیفی پژوهش و در ادامه به تفسیر نتایج پرداخته خواهد شد. جدول شماره ۳ مشخصات داده‌های مورد استفاده در تحقیق را نمایش می‌دهد.

<sup>1</sup> accuracy

<sup>2</sup> precision

<sup>3</sup> Recall

<sup>4</sup> F-measure



جدول ۳. مشخصات داده‌های مورد استفاده در تحقیق

منبع	مجموع مشتریان	تعداد مشتریان بد حساب	تعداد مشتریان خوش حساب	تعداد ویژگی‌ها	داده
بانک ملت	۱۰۰۰۰	۶۴۹	۹۳۵۱	۱۲	ایران

همانطور که مشخص است بر اساس ۱۲ ویژگی، حدود ۹۳/۵ درصد مشتریان بانک ملت در دسته خوش حساب و ۶/۵ درصد در دسته بدحساب قرار گرفته‌اند.

ویژگی‌های جمعیت شناختی داده‌های پژوهش بر اساس مشخصات مشتریان همانند سن، مکان، مبلغ وثیقه، نوع وثیقه، مبلغ تسهیلات، وضعیت اعتباری، نوع تسهیلات، مدت تسهیلات، میزان تحصیلات، جنسیت، تعداد تسهیلات، نرخ بهره و بخش اقتصادی در جدول ۴ بیان شده است.

جدول ۴. آمار توصیفی سری داده‌ای ایران (بانک ملت)

ویژگی	کمینه	بیشینه	میان	میانگین	انحراف معیار
سن	۱۶	۹۶	۳۷	۳۹/۹۳	۱۳/۸۰
مکان	۱	۳۱	۹	۱۲/۱۰	۸/۰۴
مبلغ وثیقه	۰	۲۲۶۰	۰	۱۰/۲۰	۶۲/۷۲
نوع وثیقه	۱	۵	۱	۱/۱۷	۰/۵۴
مبلغ تسهیلات	۱	۵۰۰۰	۲۵	۴۹/۴۹	۱۱۷/۳۳
وضعیت اعتباری	۱	۲	۱	۱/۰۶	۰/۲۵
نوع تسهیلات	۱	۱۰	۶	۶/۱۴	۱/۸۶
مدت تسهیلات	۰	۲۴۳	۳۶	۲۸/۸۴	۱۷/۵۳
میزان تحصیلات	۱	۷	۳	۲/۸۰	۱/۵۶
جنسیت	۱	۲	۲	۱/۶۷	۰/۴۷
تعداد تسهیلات	۱	۱۰۰۰۰	۵۰۰۸/۵۰	۵۰۰۸/۴۸	۲۸۸۲/۱۷
نرخ بهره	۰	۳۶	۱۲	۱۰/۹۱	۷/۲۵
بخش اقتصادی ۱	۱	۵	۲	۲/۲۰	۰/۹۴

جداول شماره ۵ و ۶ صحت و رتبه میانگین یادگیرنده‌های پایه تحقیق حاضر را نشان می‌دهد. تمامی الگوریتم‌های دسته‌بند به عنوان الگوریتم‌های یادگیرنده پایه تعریف شده‌اند. همان‌طور که قابل مشاهده است، الگوریتم SVMPSO از بهترین عملکرد در میان سایر الگوریتم‌های یادگیرنده پایه برخوردار است بطوریکه نرخ صحت بر روی داده‌های بانک ملت ۹۲/۹۸ درصد بوده و بدان معنی است که در ۹۲/۹۸ درصد از مواقع، مشتریان بدحساب از مشتریان خوش

حساب به درستی تشخیص داده شده‌اند. همچنین بر اساس سنجه اف، مجدداً الگوریتم SVMPSO با اختلاف زیاد در جایگاه نخست قرار می‌گیرد که نشان از قدرت عملکردی این الگوریتم دارد.

جدول ۵. صحت و رتبه میانگین یادگیرنده های پایه

رتبه میانگین	صحت	یادگیرنده پایه
۱/۰۰	۹۸/۹۲	SVMPSO
۳/۰۰	۹۸/۶۶	NN
۳/۷۵	۹۸/۵۷	AMLPS
۴/۰۰	۹۶/۲۱	LR
۵/۰۰	۹۸/۸۹	DT
۵/۵۰	۹۴/۷۵	SVM
۶/۷۵	۹۵/۴۸	KNN
۷/۰۰	۹۳/۲۹	NB

جدول ۶. سنجه F و رتبه میانگین یادگیرنده های پایه

رتبه میانگین	سنجه F	یادگیرنده پایه
۱/۰۰	۹۱/۵۴	SVMPSO
۳/۰۰	۸۹/۲۵	NN
۳/۲۵	۷۶/۶۵	LR
۳/۷۵	۸۸/۶۲	AMLPS
۴/۵۰	۹۰/۶۵	DT
۶/۵۰	۵۲/۱۱	NB
۶/۵۰	۴۸/۵۸	SVM
۷/۵۰	۵۴/۳۴	KNN

جداول شماره ۷ و ۸ نشان‌دهنده نتایج آزمون مدل‌های ترکیبی فرایادگیر بر روی داده‌های اعتباری هستند. همانطور که پیداست بر اساس هر دو معیار صحت (نرخ موفقیت) و سنجه اف (میانگین هارمونیک بین دقت و یادآوری) مدل ترکیبی فرایادگیر (KNN-NN-SVMPSO) (DBSCAN)-(DL) از بالاترین عملکرد برخوردار است. این بدین صورت است که نرخ صحت بر روی داده بانک ملت از ۹۸,۹۲ درصد در بهترین مدل یادگیرنده پایه به ۹۹,۹۰ درصد در بهترین مدل فرایادگیر ارتقا یافته است.

جدول ۷. صحت و رتبه میانگین بهترین مدل‌های ترکیبی

رتبه میانگین	صحت	مدل
۲/۰۰	۹۹/۹۰	(KNN-NN-SVMPSO)-(DL)-(DBSCAN)
۲/۱۳	۹۹/۸۰	(KNN-NN-SVMPSO)-(DL)-(SOM)

۳/۲۵	۹۹/۷۴	(KNN-NN-SVMPSO)-(DL)-(FCM)
۳/۵۰	۹۹/۷۸	(KNN-NN-SVMPSO)-(DL)-(EM)
۴/۱۳	۹۹/۷۲	(KNN-NN-SVMPSO)-(DL)-(KM)
۱۱/۸۸	۹۹/۴۸	(DT-KNN-NN)-(DL)-(FCM)
۱۲/۱۳	۹۹/۴۸	(DT-KNN-NN)-(DL)-(KM)
۱۵/۰۰	۹۹/۴۶	(KNN-NN-SVM)-(DL)-(FCM)
۱۶/۰۰	۹۹/۴۳	(NB-KNN-NN)-(DL)-(FCM)
۱۶/۵۰	۹۹/۴۲	(KNN-NN-SVM)-(DL)-(DBSCAN)
۱۷/۲۵	۹۹/۴۲	(KNN-NN-LR)-(DL)-(SOM)
۱۷/۳۸	۹۹/۵۵	(DT-KNN-NN)-(DL)-(EM)
۱۷/۷۵	۹۹/۵۵	(DT-KNN-NN)-(DL)-(DBSCAN)
۱۷/۸۸	۹۹/۴۵	(NB-KNN-NN)-(DL)-(EM)
۱۷/۸۸	۹۹/۴۶	(KNN-NN-AMLPS)-(DL)-(EM)
۱۷/۸۸	۹۹/۴۷	(KNN-NN-AMLPS)-(DL)-(FCM)
۱۸/۸۸	۹۹/۴۱	(KNN-NN-AMLPS)-(DL)-(DBSCAN)
۱۹/۰۰	۹۹/۴۷	(KNN-NN-AMLPS)-(DL)-(KM)
۱۹/۶۳	۹۹/۳۹	(KNN-NN-AMLPS)-(DL)-(SOM)
۱۹/۶۳	۹۹/۳۷	(KNN-NN-LR)-(DL)-(DBSCAN)
۲۰/۱۳	۹۹/۵۲	(DT-KNN-NN)-(DL)-(SOM)
۲۰/۵۰	۹۹/۴۴	(KNN-NN-LR)-(DL)-(KM)
۲۱/۱۳	۹۹/۴۳	(NB-KNN-NN)-(DL)-(KM)
۲۱/۲۵	۹۹/۴۲	(KNN-NN-LR)-(DL)-(FCM)
۲۲/۷۵	۹۹/۴۱	(NB-KNN-NN)-(DL)-(DBSCAN)
۲۳/۶۳	۹۹/۴۳	(KNN-NN-LR)-(DL)-(EM)
۲۳/۸۸	۹۹/۴۶	(LR-NN-AMLPS)-(DL)-(KM)
۲۴/۳۸	۹۹/۴۱	(KNN-NN-SVM)-(DL)-(KM)
۲۴/۳۸	۹۹/۳۷	(KNN-NN-SVM)-(DL)-(EM)
۲۵/۸۸	۹۹/۴۱	(NB-KNN-NN)-(DL)-(SOM)
۲۶/۵۰	۹۹/۴۵	(LR-NN-AMLPS)-(DL)-(EM)
۲۷/۰۰	۹۹/۴۰	(KNN-NN-SVM)-(DL)-(SOM)
۲۷/۷۵	۹۹/۴۳	(LR-NN-AMLPS)-(DL)-(DBSCAN)
۲۸/۰۰	۹۹/۳۹	(LR-NN-AMLPS)-(DL)-(SOM)
۳۰/۷۵	۹۹/۳۶	(LR-NN-AMLPS)-(DL)-(FCM)
۳۵/۸۸	۹۹/۳۸	(DT-NB-LR)-(DL)-(KM)
۳۶/۲۵	۹۹/۳۹	(DT-NB-LR)-(DL)-(FCM)
۳۶/۲۵	۹۹/۳۸	(DT-NB-LR)-(DL)-(DBSCAN)
۳۷/۰۰	۹۹/۳۹	(DT-NB-LR)-(DL)-(EM)
۳۷/۱۳	۹۹/۳۶	(DT-NB-LR)-(DL)-(SOM)

جدول ۸. سنجه F و رتبه میانگین بهترین مدل‌های ترکیبی

رتبه میانگین	سنجه F	مدل
۲/۰۰	۹۹/۲۳	(KNN-NN-SVMPSO)-(DL)-(DBSCAN)
۲/۱۳	۹۸/۴۵	(KNN-NN-SVMPSO)-(DL)-(SOM)
۳/۲۵	۹۷/۹۹	(KNN-NN-SVMPSO)-(DL)-(FCM)
۳/۵۰	۹۸/۲۹	(KNN-NN-SVMPSO)-(DL)-(EM)
۴/۱۳	۹۷/۸۲	(KNN-NN-SVMPSO)-(DL)-(KM)
۱۱/۳۸	۹۵/۹۵	(DT-KNN-NN)-(DL)-(FCM)
۱۳/۵۰	۹۵/۹۱	(DT-KNN-NN)-(DL)-(KM)
۱۴/۶۳	۹۵/۷۸	(KNN-NN-SVM)-(DL)-(FCM)
۱۵/۳۸	۹۵/۵۳	(KNN-NN-SVM)-(DL)-(DBSCAN)
۱۶/۷۵	۹۶/۴۵	(DT-KNN-NN)-(DL)-(EM)
۱۶/۷۵	۹۵/۶۱	(NB-KNN-NN)-(DL)-(FCM)
۱۷/۶۳	۹۵/۴۴	(KNN-NN-LR)-(DL)-(SOM)
۱۷/۷۵	۹۵/۸۰	(KNN-NN-AMLP)-(DL)-(FCM)
۱۸/۰۰	۹۵/۷۴	(NB-KNN-NN)-(DL)-(EM)
۱۸/۰۰	۹۵/۱۷	(KNN-NN-LR)-(DL)-(DBSCAN)
۱۸/۲۵	۹۵/۷۳	(KNN-NN-AMLP)-(DL)-(EM)
۱۸/۵۰	۹۶/۵۱	(DT-KNN-NN)-(DL)-(DBSCAN)
۱۸/۸۸	۹۵/۷۱	(KNN-NN-LR)-(DL)-(KM)
۱۹/۱۳	۹۵/۲۷	(KNN-NN-AMLP)-(DL)-(SOM)
۱۹/۵۰	۹۵/۲۸	(KNN-NN-AMLP)-(DL)-(DBSCAN)
۱۹/۸۸	۹۵/۵۲	(NB-KNN-NN)-(DL)-(DBSCAN)
۲۰/۱۳	۹۵/۸۷	(KNN-NN-AMLP)-(DL)-(KM)
۲۰/۸۸	۹۶/۲۳	(DT-KNN-NN)-(DL)-(SOM)
۲۱/۰۰	۹۵/۴۸	(NB-KNN-NN)-(DL)-(KM)
۲۱/۸۸	۹۵/۴۷	(KNN-NN-LR)-(DL)-(FCM)
۲۲/۳۸	۹۵/۵۲	(KNN-NN-LR)-(DL)-(EM)
۲۴/۱۳	۹۵/۳۹	(KNN-NN-SVM)-(DL)-(KM)
۲۴/۳۸	۹۵/۷۶	(LR-NN-AMLP)-(DL)-(KM)
۲۵/۶۳	۹۵/۳۹	(NB-KNN-NN)-(DL)-(SOM)
۲۵/۸۸	۹۵/۰۰	(KNN-NN-SVM)-(DL)-(EM)
۲۶/۱۳	۹۵/۴۱	(KNN-NN-SVM)-(DL)-(SOM)
۲۶/۷۵	۹۵/۶۲	(LR-NN-AMLP)-(DL)-(EM)
۲۸/۶۳	۹۵/۱۵	(LR-NN-AMLP)-(DL)-(SOM)
۲۸/۶۳	۹۵/۴۷	(LR-NN-AMLP)-(DL)-(DBSCAN)
۳۰/۷۵	۹۴/۹۴	(LR-NN-AMLP)-(DL)-(FCM)
۳۵/۶۳	۹۵/۰۷	(DT-NB-LR)-(DL)-(KM)
۳۶/۵۰	۹۵/۰۲	(DT-NB-LR)-(DL)-(DBSCAN)
۳۷/۲۵	۹۵/۱۲	(DT-NB-LR)-(DL)-(EM)
۳۷/۲۵	۹۴/۸۴	(DT-NB-LR)-(DL)-(SOM)
۳۷/۳۸	۹۵/۰۷	(DT-NB-LR)-(DL)-(FCM)

ذکر این نکته ضروری است که حتی مقدار اندکی افزایش عملکرد در مدل‌های اعتبارسنجی در بانک‌های بزرگ باعث افزایش سودآوری و کاهش میزان اعتبارات مشکل دار خواهد شد. به همین دلیل این بهبود عملکرد که به واسطه مدل‌های ترکیبی فرایادگیر حاصل شده است، قابل توجه است.

در این مدل ترکیبی فرایادگیر، بخش یادگیرنده پایه توسط الگوریتم های طبقه بند KNN، NN و SVMPSO شکل گرفته اند و در قسمت میانی یا فرایادگیر الگوریتم یادگیری عمیق نقش حیاتی را بازی کرده است. همچنین در قسمت پایانی یا الگوریتم خوشه بند، الگوریتم هایی با پیچیدگی و قدرت عملکردی بالاتر نقش مهم تری را در افزایش عملکرد کلی مدل ایفا کرده اند به نحوی که به ترتیب الگوریتم های DBSCAN، SOM و FCM بیشترین نرخ صحت و سنججه اف را برای این مدل ها رقم زده اند.

عملکرد بهترین مدل‌های پایه و ترکیبی به صورت میانگین در جدول شماره ۹ مقایسه شده‌اند.

جدول ۹. مقایسه عملکرد میانگین بهترین مدل‌های پایه و ترکیبی

بهترین مدل ترکیبی		بهترین مدل پایه	
(KNN-NN-SVMPSO)-(DL)-(DBSCAN)		SVMPSO	
صحت	Fسنجه	صحت	Fسنجه
۹۹/۹۰	۹۹/۲۳	۹۸/۹۲	۹۱/۵۴

همانطور که پیش‌تر به آن اشاره شده بود مدل SVMPSO بهترین یادگیرنده پایه و مدل ترکیبی فرایادگیر (KNN-NN-SVMPSO)-(DL)-(DBSCAN) بهترین عملکرد را داشته‌اند. عملکرد مدل SVMPSO بر اساس سنججه اف در هر چهار داده بطور میانگین برابر ۹۴ درصد و بر اساس صحت ۲۱/۹۷ درصد بوده است. این در حالی است که پس از استفاده از مدل ترکیبی فرایادگیر (KNN-NN-SVMPSO)-(DL)-(DBSCAN) سنججه اف در هر چهار داده به‌طور میانگین به ۶۱/۹۹ درصد و صحت به ۸۲/۹۹ درصد افزایش پیدا کرده اند. بدین ترتیب در این دو شاخص به ترتیب شاهد نرخ بهبود ۹۷/۵ درصدی و ۶۸/۲ درصدی بوده ایم که نشان از قدرت این مدل ترکیبی فرایادگیر دارد.

جدول ۱۰ به تشریح ماتریس سردرگمی و سنجش عملکرد بهترین مدل ترکیبی بر روی داده‌های بانک ملت پرداخته است. همانطور که مشخص است، در داده واقعی بانک ملت ۹۳۵۵ مشتری خوش حساب و ۶۴۵ مشتری بدحساب وجود دارد. با استفاده از مدل ترکیبی فرایادگیر بیان شده، ۹۳۴۸ مورد از مشتریان خوش حساب به درستی خوش حساب تشخیص داده شده اند و فقط ۷ مشتری به اشتباه بدحساب محسوب شده‌اند. در طرف دیگر، این مدل از میان ۶۴۵ مشتری بدحساب ۶۴۲ مورد را به درستی و فقط ۳ مورد را به اشتباه تشخیص داده است. قسمت

دوم جدول ۱۰ به بررسی سنجش عملکرد این مدل پرداخته است. بر این اساس نرخ معیار های صحت، دقت، یادآوری، سنجه اف، مثبت کاذب (خطای نوع اول) و منفی کاذب (خطای نوع دوم) به ترتیب ۹۰/۹۹، ۵۳/۹۹، ۹۲/۹۸، ۲۳/۹۹، ۰۳/۰، و ۰۸/۱ درصد محاسبه شده است. درضمن در این ماتریس سردرگمی، مشتریان بدحساب به عنوان کلاس مثبت در نظر گرفته شده اند.

جدول ۱۰. ماتریکس سردرگمی و سنجش عملکرد بهترین مدل ترکیبی بر روی داده ایران (بانک ملت)

ماتریکس سردرگمی		
بد حساب	خوش حساب	
۷	۹۳۴۸	پیش بینی شده به عنوان خوش حساب
۶۴۲	۳	پیش بینی شده به عنوان بد حساب
سنجش عملکرد		
٪۹۹/۹۰		صحت
٪۹۹/۵۳		دقت
٪۹۸/۹۲		یادآوری
٪۹۹/۲۳		سنجه اف
٪۰/۰۳		مثبت کاذب (خطای نوع اول)
٪۱/۰۸		منفی کاذب (خطای نوع دوم)
توضیح: مشتریان بدحساب به عنوان کلاس مثبت در نظر گرفته شده اند.		

در ادامه با استفاده از انواع روش های استخراج و انتخاب ویژگی مانند تجزیه و تحلیل اصل جزء (PCA)، شاخص جینی (Gini)، نسبت اطلاعات بهره (IGR) و اطلاعات بهره (IG) نسبت به محاسبه وزن ویژگی‌ها و رتبه میانگین آن‌ها اقدام شد. بر طبق نتایج این روش‌ها ویژگی‌هایی همچون میزان وثیقه، نوع وثیقه و میزان تسهیلات به ترتیب مهم‌ترین ویژگی‌ها در تشخیص مشتریان خوب از بد بوده اند. از طرف دیگر ویژگی‌های همچون جنسیت، تحصیلات، موقعیت مکانی به ترتیب کم اهمیت‌ترین ویژگی‌ها در تشخیص مشتریان خوب از بد بوده اند.

جدول ۱۱. وزن ویژگی‌ها و رتبه میانگین آن‌ها بر اساس مدل‌های مختلف

رتبه میانگین	PCA	Gini	IGR	IG	ویژگی‌ها
۱/۳۸	۰/۱۸۳۳	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	میزان وثیقه
۳/۳۸	۰/۰۰۰۳	۰/۹۵۰۴	۱/۰۰۰۰	۰/۹۱۹۱	نوع وثیقه
۳/۵۰	۱/۰۰۰۰	۰/۰۳۵۴	۰/۰۶۸۷	۰/۴۷۴۰	میزان تسهیلات
۳/۵۰	۰/۰۱۲۹	۰/۱۲۹۳	۰/۱۱۶۵	۰/۴۹۰۵	مدت تسهیلات
۵/۵۰	۰/۰۱۷۳	۰/۰۰۷۹	۰/۰۱۴۸	۰/۴۷۴۰	نرخ بهره
۶/۰۰	۰/۰۰۲۳	۰/۰۲۱۷	۰/۰۴۸۲	۰/۰۲۳۲	نوع تسهیلات
۶/۵۰	۰/۰۰۰۳	۰/۰۰۹۳	۰/۰۲۷۷	۰/۰۲۶۴	بخش اقتصادی
۷/۰۰	۰/۰۱۴۵	۰/۰۰۱۴	۰/۰۰۰۲	۰/۴۷۴۰	سن
۸/۷۵	۰/۰۰۰۰	۰/۰۰۱۸	۰/۰۰۲۷	۰/۰۱۴۶	موقعیت مکانی
۱۰/۰۰	۰/۰۰۰۰	۰/۰۰۰۴	۰/۰۰۰۸	۰/۰۰۰۶	تحصیلات

جنسیت	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۱۰/۵۰
-------	--------	--------	--------	--------	--------	-------

همانطور که از جدول ۱۱ مشخص است ویژگی میزان وثیقه بر طبق سه روش از چهار روش بالا، موثرترین ویژگی در تشخیص مشتریان خوش حساب از بد حساب شناخته شده است. در مقابل ویژگی جنسیت، کمترین اهمیت را در تعیین مشتریان خوش حساب از بد حساب دارد.

## ۵. بحث و نتیجه گیری

نتایج پژوهش حاضر حاکی از آن است که استفاده از روش‌های نوین اعتبار سنجی می‌تواند منجر به ارتقا درک و فهم بانک‌ها و موسسات مالی از وضعیت اعتباری مشتریان گردد. در پژوهش حاضر با استفاده از چندین مدل یادگیرنده پایه سعی شد تا میزان توانایی مدل‌های رایج اعتبارسنجی مشخص گردد. همچنین تلاش شد با استفاده از مدل تعمیم پشته ای بر اساس ساختار مدل هیبریدی کلاسیک<sup>۱</sup> مسایل اعتبار سنجی با دقت و صحت بیشتری حل شود. به دلیل اینکه مدل‌های خوشه‌بندی جز تکنیک‌های یادگیری ماشین غیرنظارتی هستند نمی‌توانند مانند یک تکنیک نظارتی، داده‌ها را با دقت شناسایی و تفکیک نمایند. بنابراین یک روش طبقه‌بندی ابتدا به عنوان روش آموزش دهنده استفاده شده و سپس خروجی آن به عنوان ورودی روش خوشه بندی مورد استفاده قرار گرفت. وجه تمایز پژوهش حاضر استفاده از مدل تعمیم پشته‌ای در قسمت اول مدل (طبقه‌بندی) است. مدل تعمیم پشته ای قابلیت ترکیب چندین طبقه‌بند پایه‌ای<sup>۲</sup> را دارد. و به همین دلیل در پژوهش حاضر قدرت یادگیری و پیش بینی مدل را به طور چشمگیری افزایش داده است.

نتایج پژوهش حاکی از آن است که الگوریتم SVMPSO از بهترین عملکرد در میان سایر الگوریتم‌های یادگیرنده پایه برخوردار است بطوریکه نرخ صحت بر روی داده بانک ملت بسیار بالا برآورد شده است (۹۲/۹۸ درصد). بدین معنی که در ۹۲/۹۸ درصد از مواقع، مشتریان بدحساب از مشتریان خوش حساب به درستی تشخیص داده شده اند. همچنین بر اساس سنجه F، مجدداً الگوریتم SVMPSO با اختلاف زیاد در جایگاه نخست نسبت به سایر الگوریتم‌های پایه قرار گرفت که نشان از قدرت عملکردی این الگوریتم دارد. همچنین بر حسب نتایج به دست آمده از مقایسه مدل‌های فرایادگیر، بر اساس هر دو معیار صحت (نرخ موفقیت) و سنجه اف (میانگین هارمونیک بین دقت و یادآوری) مدل ترکیبی فرایادگیر (KNN-NN- (SVMPSO)-(DL)-(DBSCAN) از بالاترین عملکرد نسبت به سایر مدل‌های ترکیبی فرایادگیر برخوردار است. نتایج نشان می‌دهند که نرخ صحت بر روی داده بانک ملت از ۹۲/۹۸

<sup>1</sup> Classification + Clustering

<sup>2</sup> Base Classifiers

درصد در بهترین مدل یادگیرنده پایه به ۹۰/۹۹ درصد در بهترین مدل فرایادگیر ارتقا یافته‌است. ذکر این نکته ضروری است که حتی مقدار اندکی افزایش عملکرد در مدل‌های اعتبارسنجی در بانک‌های بزرگ باعث افزایش سودآوری و کاهش میزان اعتبارات مشکل‌دار خواهد شد. به همین دلیل این بهبود عملکرد که به واسطه مدل‌های ترکیبی فرایادگیر حاصل شده است، قابل توجه است.

همچنین در الگوریتم خوشه بند، الگوریتم‌هایی با پیچیدگی و قدرت عملکردی بالاتر نقش مهم‌تری را در افزایش عملکرد کلی مدل ایفا کردند به نحوی که به ترتیب الگوریتم‌های SOM، DBSCAN و FCM بیشترین نرخ صحت و سنجه F را برای این مدل‌ها رقم زدند.

در ادامه با استفاده از انواع روش‌های استخراج و انتخاب ویژگی مانند تجزیه و تحلیل اصل جزء (PCA)، شاخص جینی (Gini)، نسبت اطلاعات بهره (IGR) و اطلاعات بهره (IG) نسبت به محاسبه وزن ویژگی‌ها و رتبه میانگین آن‌ها اقدام و نشان داده شد که ویژگی‌هایی همچون میزان وثیقه، نوع وثیقه و میزان تسهیلات به ترتیب مهم‌ترین ویژگی‌ها در تشخیص مشتریان خوب از بد بوده‌اند. از طرف دیگر ویژگی‌های همچون جنسیت، تحصیلات، موقعیت مکانی به ترتیب کم‌اهمیت‌ترین ویژگی‌ها در تشخیص مشتریان خوب از بد بوده‌اند. این نتایج می‌تواند به بانک‌ها کمک کند تا بر اساس این ویژگی‌ها نسبت به ارائه تسهیلات به مشتریان کم‌ریسک و خوش حساب اقدام کنند.

با توجه به نتایج پژوهش حاضر و با توجه به بحران اعتباری در سیستم بانکی کشور، به هیات‌مدیره بانک ملت و سایر بانک‌ها پیشنهاد می‌شود که برای اعتبارسنجی مشتریان خود از الگوریتم یادگیرنده SVMPSO و مدل ترکیبی فرایادگیر (DL)-(KNN-NN-SVMPSO) (DBSCAN) استفاده نمایند. همچنین بر اساس نتایج روش‌های تجزیه و تحلیل اصل جزء (PCA)، شاخص جینی (Gini)، نسبت اطلاعات بهره (IGR) و اطلاعات بهره (IG) پیشنهاد می‌شود که مدیران بانک‌های کشور در ارزیابی ریسک اعتباری مشتریان به ترتیب به معیارهای میزان وثیقه، نوع وثیقه و میزان تسهیلات، وزن بیشتری اختصاص دهند.

با توجه به تفاوت عملکردی بین بانک‌های داخلی به سایر محققان پیشنهاد می‌شود مدل ترکیبی فرایادگیر (DL)-(KNN-NN-SVMPSO) (DBSCAN) را برای دیگر بانک‌های کشور اجرا نموده و با نتایج سایر روش‌ها مقایسه نمایند.

از محدودیت‌های پژوهش حاضر می‌توان به عدم وجود پایگاه داده مشخص و مدون در بانک ملت برای ثبت و ضبط فعالیت‌های اعتباری مشتریان اشاره کرد. این محدودیت باعث افزایش حجم محاسبات محققان و گاهی منجر به تغییر سنج‌های پیشنهاد شده توسط محققان خارجی، گردید.



## منابع

1. Abzari, M., Nazemi, A., & Abdolmanafi, S. (2005). Data Mining and Customer Relationship Management (CRM) in Banks. Paper presented at the Third International Management Conference. <https://civilica.com/doc/65975>
2. Addo, P. M., Guegan, D., & Hassani, B. J. R. (2018). Credit risk analysis using machine and deep learning models. 6(2), 38.
3. Breuel, T., & Shafait, F. (2010). Automlpl: Simple, effective, fully automated learning rate and size adjustment. Paper presented at the The Learning Workshop.
4. Dadmohammadi, D., & Ahmadi, A. (2015). Credit ranking of bank customers with neural network with lateral connections *Journal of Development In Monetary and Banking Management*, 2(3), 1-28.
5. Denison, D. G., Holmes, C. C., Mallick, B. K., & Smith, A. F. (2002). Bayesian methods for nonlinear classification and regression (Vol. 386): John Wiley & Sons.
6. Eberhart, R. C., Shi, Y., & Kennedy, J. (2001). Swarm intelligence: Elsevier.
7. Ghasemi, A., & Donyayiharis, T. (2016). Credit Risk Measurement In one of the state-owned banks with a Neural Network Approach. *Journal of Financial Engineering and Securities Management*, 27, 155-181.
8. Giudici, P., Hadji-Misheva, B., & Spelta, A. (2020). Network based credit risk models. *Quality Engineering*, 32(2), 199-211.
9. Haykin, S. (2004). A comprehensive foundation. Neural networks, 2(2004), 41.
10. Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied logistic regression (Vol. 398): John Wiley & Sons.
11. Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. Paper presented at the Proceedings of ICNN'95-international conference on neural networks.
12. Khansari, R., & Fallahshams, M. (2010). Appraising the Use of KMV Model in Predicting Default of Companies Listed in Tehran Stock Exchange %J *Financial Research Journal*. 11(28), -.
13. Mehrara, M., & Sadeghian, S. (2008). Determining the optimal loan composition in economic sectors: (Saman Bank case study). *Financial Economics*, 2(5), 116-134.
14. Mismar, F. N., & Bhatti, M. I. (2020). The Determinants of Credit Risk: An Evidence from *ASEAN and GCC Islamic Banks*. 13(5), 89.
15. mohamadi, T., shakeri, A., Eskandari, F., & Karimi, D. (2017). Factors Shaping the Non-performing Loans in Iranian Banking System: A Case Study, *Majlis and Rahbord*. 24(89), 269-300.
16. Nilchi, M., Moghadam, K., SadrAbadi, A., & Farhadian, A. (2019). Predicting the Credit Risk of Loans Using Data Mining Tools. *Journal of Monetary and Banking research*, 11(38).(in persian).
17. Roussopoulos, N., Kelley, S., & Vincent, F. (1995). Nearest neighbor queries. Paper presented at the Proceedings of the 1995 ACM SIGMOD international conference on Management of data.
18. Tehrani, R., & Fallahshamsi, M. (2005). Designing and explaining the credit risk model in the country's banking system Article. *Social Sciences and Humanities (Shiraz University)*, 43, 45-60.

19. Thomas, L. C. J. I. j. o. f. (2000). A survey of credit and behavioural scoring: forecasting financial risk of lending to consumers. 16(2), 149-172.
20. Tisan, A., Cirstea, M. J. M., & Simulation, C. i. (2013). SOM neural network design—A new Simulink library based approach targeting FPGA implementation. 91, 134-149.
21. Tsai, C.-F., & Chen, M.-L. J. A. s. c. (2010). Credit rating by hybrid machine learning techniques. 10(2), 374-380.
22. Umar, M., Ji, X., Mirza, N., & Naqvi, B. (2021). Carbon neutrality, bank lending, and credit risk: Evidence from the Eurozone. *Journal of Environmental Management*, 296, 113156.
23. Xi-yu, F. X.-f. L. (2006). New Evolution and Development Preview of Decision Tree in Data Mining [J]. *Information Technology Informatization*, 3.
24. Xin, J., & Xiaofeng, H. J. J. o. C. I. T. (2012). A quantum-PSO-based
25. Zopounidis, C., & Doumpos, M. J. T. (2013). Multicriteria decision systems for financial problems. 21(2), 241-261.

---

#### استناد

قاسمی ارمکی، علی؛ فلاح، میرفیض و البرزی، محمود (۱۴۰۱). توسعه و تبیین نظام اعتبارسنجی مشتریان بانک‌ها بر اساس مدل‌های هیبریدی فرایادگیر: مورد مطالعه، بانک ملت. *چشم‌انداز مدیریت مالی*، ۱۲ (۳۷)، ۶۷-۹۲.

---

#### Citation

Ghasemi Armaky, Ali; Fallah, Mirfeiz & Alborzi, Mahmoud (2022). Development and Explanation of Bank Customers' Credit System Based on Hybrid Learning Models: A Case Study of Bank Mellat. *Journal of Financial Management Perspective*, 12(37), 67 - 92. (in Persian)

---