

## A model based on random forest algorithm and Jaya optimization to predict bank customer churn

Sepideh Chehreh<sup>✉1</sup>  and Ali Sarabadani<sup>2</sup> 

1. Corresponding author, Ph.D. Student in information technology engineering specializing in multimedia systems, Faculty of Engineering and Technology, Qom University, Qom, Iran. Email: [chehreh.sepideh1@gmail.com](mailto:chehreh.sepideh1@gmail.com)
2. Ph.D. Student in information technology engineering specializing in Electronic commerce, Faculty of Engineering and Technology, Qom University, Qom, Iran. Email: [alisarabadani14@gmail.com](mailto:alisarabadani14@gmail.com)

Article Info	ABSTRACT
<b>Article type:</b> Research Article	Customer churn is a financial term that refers to the loss of a customer. Due to many banks, losing customers from one bank to another has become a severe concern for different banks. Therefore, in this article, which has been compiled for the customers of a bank, it is possible to identify customers who have a high probability of falling by considering the behavior and characteristics of the customers before the fall occurs and to keep them by providing suggestions. In marketing, everyone agrees that keeping a customer is much less expensive than attracting a new customer, so this article introduces the different phases of predicting customer churn with the help of machine learning. The proposed method combines random forest algorithms and Jaya optimization, and customer dropout is based on different characteristics. Customers like age, Gender, c graphs, and cases. It predicts more. The results of the proposed model in the article are 91.41%, 95.66%, and 93.35%, respectively, in Precision, Recall, and Accuracy criteria.
<b>Article history:</b> Received 2023 August 31 Received in revised form 2023 October 21 Accepted 2024 December 19 Published online 2024 March 15	
<b>Keywords:</b> customer churn, machine learning, random forest algorithm, site optimization.	

**Cite this article:** Chehreh, S. & Sarabadani, A. (2023). A model based on random forest algorithm and Jaya optimization to predict bank customer churn. *Engineering Management and Soft Computing*, 9 (2). 132-148. DOI: <https://doi.org/>



© The Author(s)  
DOI: <https://doi.org/>

**Publisher:** University of Qom

## ارائه مدلی مبتنی بر الگوریتم جنگل تصادفی و بهینه‌سازی جایا برای پیش‌بینی ریزش مشتریان بانکی

سپیده چهره<sup>۱</sup> و علی سرآبادانی<sup>۲</sup>

۱. نویسنده مسئول، نویسنده مسئول، دانشجوی دکترا رشته مهندسی فناوری اطلاعات گرایش سیستم‌های چند رسانه‌ای، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران.  
رايانame: [chehreh.sepideh1@gmail.com](mailto:chehreh.sepideh1@gmail.com)

۲. دانشجوی دکترا رشته مهندسی فناوری اطلاعات گرایش تجارت الکترونیک، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران. رايانame: [alisarabadani14@gmail.com](mailto:alisarabadani14@gmail.com)

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	ریزش مشتری، یک اصطلاح مالی است که به از دست دادن مشتری اشاره دارد. امروزه با توجه به تعداد زیاد بانک‌ها، ریزش مشتریان از یک بانک به بانک دیگر تبدیل به دغدغه جدی برای بانک‌های مختلف شده است. بنابراین در این مقاله که برای مشتریان یک بانک گردآوری شده است، می‌توان با توجه به رفتار و ویژگی‌های مشتریان قبل از وقوع ریزش، به شناسایی مشتریانی که احتمال ریزش بالایی دارند، پرداخت و با ارائه پیشنهادهایی آنها را حفظ نمود. در بازاریابی همه بر این امر توافق دارند که حفظ یک مشتری از جذب یک مشتری جدید بسیار کم‌هزینه‌تر است. از این رو این مقاله به معرفی فازهای مختلف رویکرد پیش‌بینی مشتری ریزشی با کمک یادگیری ماشین پرداخته است. روش پیشنهادی ترکیبی از الگوریتم‌های جنگل تصادفی و بهینه‌سازی جایا می‌باشد و ریزش مشتری را براساس ویژگی‌های مختلف مشتری مانند سن، جنسیت، جغرافیا و موارد دیگر پیش‌بینی می‌کند. نتایج حاصل از مدل پیشنهادی در مقاله به ترتیب در معیارهای Precision، Recall و Accuracy برابر مقادیر ۹۱.۴۱، ۹۵.۶۶ و ۹۳.۳۵ درصد می‌باشد.
تاریخ دریافت:	۱۴۰۲/۰۶/۰۹
تاریخ بازنگری:	۱۴۰۲/۰۷/۲۹
تاریخ پذیرش:	۱۴۰۲/۰۹/۲۸
تاریخ انتشار:	۱۴۰۲/۱۲/۲۵
کلیدواژه‌ها:	مدیریت عدم قطعیت، تحلیل احساسات، نظریه امکان، وردنت فازی.

استناد: چهره، سپیده و سرآبادانی، علی. (۱۴۰۲). «ارائه مدلی مبتنی بر الگوریتم جنگل تصادفی و بهینه‌سازی جایا برای پیش‌بینی ریزش مشتریان بانکی». مدیریت مهندسی و رایانش نرم، دوره ۹ (۲). صص: ۱۳۲-۱۴۸. <https://doi.org/10.26481/jemsc.1402.132-148>.



© نویسنده‌گان.

ناشر: دانشگاه قم

## (۱) مقدمه

در کسب و کار امروز، تبلیغ‌ها و آگهی‌های زیادی در همه جا از جمله تلویزیون، اینترنت ظاهر می‌شوند و مشتری یک خدمت و یا محصول را در معرض بسیاری از پیشنهادهای اغواکننده قرار می‌دهد. بنابراین بسیاری از مشتریان، شرکت ارائه‌دهنده خدمات، محصول خود را تغییر می‌دهند تا از مزایای این پیشنهادها بهره ببرند (امین، ۲۰۱۷). نقشه سفر مشتری، مجموعه کاملی از تجربه‌هایی است که مشتری هنگام تعامل با یک سازمان و برنده بددست می‌آورد. این نقشه کمک می‌کند تا تجربه مشتری با آن سازمان از یک خدمت مقطوعی و گذرا به یک رابطه طولانی‌مدت تبدیل شود.

مرحله‌های مختلف سفر مشتری شامل فاز آگاهی و اطلاع، علاقه‌مندی، بررسی و ارزیابی، خرید، حفظ و نگهداشت و وفاداری است. مرحله حفظ و نگهداشت زمانی است که مشتری خدمات موردنیاز را از سازمان مربوطه دریافت کرده است و ممکن است به دلایل مختلف در معرض جدایی از سازمان قرار بگیرد. از این رو در این مرحله سازمان بایستی با بکارگیری روش‌های موثر، مشتریانی که احتمال ریزش دارند را شناسایی کرده و برای حفظ و نگهداشت آنها تلاش کند.

امروزه اصطلاح ریزش<sup>۸۸</sup> مشتری به خوبی در کسب و کارهای مختلف شناخته شده است. مشتریانی ریزشی یا ریزش‌کننده<sup>۸۹</sup> محسوب می‌شوند که احتمالاً پس از استفاده از خدمات‌های ارائه شده علاقه خود را به ادامه کار با آن کسب و کار از دست می‌دهند و برای استفاده از خدمات آتی به سراغ سازمان رقیب می‌روند (کندل، ۲۰۱۹). در واقع احتمالاً سفر مشتری نیمه تمام باقی می‌ماند و این مشتری به دسته مشتری‌های وفادار نمی‌پیوندد.

مسئله ریزش مشتری تاثیر زیادی بر سود سازمان مربوطه دارد و یکی از مهمترین موضوعات در کسب و کارها با بازار اشباع شده می‌باشد (احمد و خان و بسیط ولی، ۲۰۲۲). بسیاری از کسب و کارها در حوزه‌های خدمات مالی، خدمات فروش بلیط خطوط هوایی، خدمات بیمه، بازی‌های آنلاین و حوزه بانکی تلاش می‌کنند تا هرچه بیشتر روابط بلندمدت خود را با مشتریان موجود حفظ کنند. مشتریان پایدار علاوه بر آنکه به عنوان مشتریان بلندمدت برای سازمان سودمند هستند، سفیران تبلیغاتی موثر کسب و کارها در بازار محسوب می‌شوند (امین و عبدیات و ادمان و لو و انوار، ۲۰۱۹). از این رو روش‌های پیش‌بینی ریزش مشتریان (CCP<sup>۹۰</sup>) در این حوزه از کسب و کارها بسیار سودمند است. بنابراین فرآیند پیش‌بینی ریزش باید زودتر از ریزش انجام شود تا سازمان زمان کافی برای پیشگیری از این رفتار را داشته باشد.

## (۲) پیشینه پژوهش

### (۱-۲) پیشینه نظری

در این بخش به تئوری‌ها، دیدگاه‌ها و رویکردهای موجود در مورد مسئله پیش‌بینی ریزش مشتری، مدیریت ارتباط با مشتری و یادگیری ماشین توضیح‌هایی مطرح شده است.

## (۳) پیش‌بینی ریزش مشتری

امروزه با توجه به افزایش رقابت بین کسب و کارها، بحث ریزش مشتریان اهمیت زیادی یافته است. ریزش مشتری یک

<sup>88</sup>. Churn

<sup>89</sup>. Churner

<sup>90</sup>. Customer Churn Prediction.

واقعیت در دنک است که همه کسب و کارها به نحوی با آن سروکار دارند حتی بزرگترین و موفق ترین شرکت‌ها هم از ریزش مشتری رنج می‌برند.

از دست دادن مشتری یکی از عواملی است که منجر به کاهش سودآوری شرکت شده و حتی ممکن است ضررهاي نیز از جنبه‌های مختلف مالی، اجتماعی و مواردی از این قبیل را به همراه داشته باشد. از آنجاکه حفظ و نگهداری مشتریان با ارزش فعلی سازمان نسبت به جذب مشتریان جدید هزینه بسیار کمتری دربر دارد، برای صاحبان کسب و کار ضروری است نگاهی دقیق به استراتژی حفظ مشتریان داشته باشند و برنامه دقیقی برای این منظور تدوین نمایند. شرکت‌های مشتری محور می‌باشند به ایجاد روابط بلندمدت با مشتریان خود توجه نمایند و علاوه بر تلاش برای به دست آوردن مشتریان جدید، بر روی اتخاذ رویکردهای مناسب برای حفظ مشتریان فعلی خود تمرکز کنند. با تدوین استراتژی‌های مؤثر حفظ مشتری، شرکت‌ها می‌توانند از هزینه‌های خدمات پایین‌تر توأم با درآمد بالاتر بهره‌مند گردند. امروزه هزینه جذب یک مشتری جدید به مرتب بیشتر از حفظ یک مشتری موجود است (بریتو و گوبیناف، ۲۰۲۱). پیش‌بینی ریزش مشتریان بطور کلی شامل مزایای زیر است:

- افزایش سود: حفظ مشتریان موجود آسان‌تر و مقرن به صرفه‌تر از جذب مشتریان جدید است.
  - جلوگیری از اتلاف درآمد: اثر از دست دادن مشتری طولانی‌مدت است و می‌تواند همه چیز را از درآمد تا فرصت‌های رقابتی تحت تأثیر قرار دهد. از این رو کسب و کارها می‌خواهند که درآمد تقلیل یافته به سبب مشتری از دست رفته را به حداقل برسانند.
  - کاهش هزینه‌های بازاریابی و فروش: هزینه نگهداری مشتری معمولاً ۱۵ تا ۱۵ برابر کمتر از هزینه جذب مشتری جدید است.
  - بهبود کیفیت خدمات به مشتری: با دانستن دلایل ریزش می‌توان کیفیت خدمات به مشتریان را ارتقا داد.
  - حفظ مشتریان بیشتر: راه اندازی فعالانه کارزار تبلیغاتی و راهبردهایی که سبب می‌شود که ریزش مشتریان را به مقدار نزدیک به صفر رساند.
  - برگرداندن مشتریان ریزشی: با شناسایی علل ریزش مشتریان قبلی و بکارگیری استراتژی‌های جذب مجدد، سعی برای برگرداندن مشتریان گذشته می‌شود.
- با توجه به مزایای ذکر شده برای پیش‌بینی ریزش مشتریان، شرکت‌ها نیازمند یک سیستم پیش‌بینی کننده موثری هستند که بتوانند مشتریانی را که احتمال ریزش دارند را به طور خودکار تشخیص دهند. مدل‌های پیش‌بینی معمولاً براساس الگوهای استفاده مشتری از سرویس و سایر عوامل که به طور مستقیم یا غیرمستقیم بر نظر او تاثیر می‌گذارد، ساخته می‌شوند (امین، ۲۰۲۰). در پیش‌بینی ریزش مشتریان درصد احتمال ترک سازمان برای هر مشتری محاسبه شده و در مجموعه داده‌های شرکت ثبت می‌شود. این فرآیند، سازمان را قادر می‌سازد که با تعریف آستانه احتمالی برای ریزش و همچنین خوشبندی مشتریان، برنامه‌های استراتژیک متفاوتی را برای هر خوش بکار گیرد تا بتواند ریزش گذشته را حفظ کند (کستیک و سینیک، ۲۰۲۰).

#### (۴) مدیریت ارتباط با مشتری

در چند سال اخیر مدیریت ارتباط با مشتریان در حوزه بازاریابی، فناوری اطلاعات و موارد مشابه توجه فراوانی را به خود جلب نموده است. مدیریت ارتباط با مشتری راهبردی تجاری برای بهبود منافع، مزايا و رضایت مشتری با سازماندهی بر اساس مشتری، پرورش رفتارهای رضایت‌بخش مشتری و اجرای فرایندهای مشتری محور می‌باشد (باران و استانک، ۲۰۱۹). مدیریت ارتباط با مشتری مجموعه‌ای از فرآیندهای تعاملی است که با هدف رسیدن به تعامل مطلوب بین سرمایه‌گذاری‌های صنعت و تحقق نیازهای مشتری بهمنظور رسیدن به حداکثر سود است. (بالیوا و کاناوا و ساندر و کومار، ۲۰۲۱). بی‌شک می‌توان گفت مهمترین دارایی اغلب سازمان‌ها مشتریان آن هستند و مشتریان اغلب به خاطر ارتباط مستقیمی که با اقدام‌های یک سازمان دارند، منبع ارزشمندی برای فرصت‌ها و تهدیدهای مرتبط با آن سازمان محسوب می‌شوند (ونگ و شن و شو، ۲۰۲۱).

#### (۵) یادگیری ماشین

یادگیری ماشین زمینه نسبتاً جدیدی از هوش مصنوعی است که در حال حاضر دوران رشد و تکامل خود را می‌گذراند و یادگیری ماشین یک زمینه تحقیقاتی بسیار فعال در علوم کامپیوتر است. علوم مختلفی از قبیل هوش مصنوعی، روانشناسی، فلسفه، تئوری اطلاعات، آمار و اطلاعات، تئوری کنترل با یادگیری ماشین در ارتباط هستند. یادگیری ماشین عبارت است از اینکه چگونه می‌توان برنامه‌ای نوش特 که از طریق تجربه یادگیری کرده و عملکرد خود را بهتر کند (احمد و افضل و صدیق و احمد و خورشید، ۲۰۲۰).

در یادگیری ماشین با استفاده از تئوری اطلاعات، مدل‌های ریاضی ساخته می‌شود که می‌تواند برای استنتاج استفاده شوند. تکنیک‌های یادگیری ماشین در شرایطی مناسب است که هیچ‌گونه دانش اولیه در مورد الگوهای داده‌ها وجود ندارد. به همین دلیل گاهی به این روش‌ها پایین به بالا می‌گویند (تکونبو و چاپار و تلونی و چیف و سیکان، ۲۰۲۲).

اهمیت مدیریت ریزش مشتری روزبه روز برای کسب و کارها بیشتر می‌گردد. پس با اعمال فرآیند یادگیری ماشین، می‌توان طی کاوش در تعامل‌های ثبت‌شده سازمان با مشتریان، به استخراج الگوهایی برای پیش‌بینی رفتار ریزش مشتری نائل آمد و مدیران را در اخذ تصمیم‌های لازم برای حفظ این مشتریان و کاهش روند ریزش آنها یاری داد (والوری و پاتیل، ۲۰۲۱). یکی از معیارهای پیش‌بینی ریزش مشتریان براساس بررسی روند رفتار آنها در مدت ارتباط با سازمان، مقایسه تعداد روز سپری شده از آخرین سفارش نسبت به بزرگ‌ترین فاصله زمانی ثبت سفارش توسط وی است. این پارامتر می‌تواند به عنوان معیاری برای پیش‌بینی ریزش در یادگیری ماشین مورداً استفاده قرار گیرد. ریزش و از دست دادن مشتری به عنوان یک مسئله مهم و بحرانی در مدیریت ارتباط با مشتری پدیدار شده است. (مونیر و علقمدی و تیب و غالب، ۲۰۲۲).

پیش‌بینی ریزش مشتریان یک مسئله بسیار پیچیده است که چالش‌هایی نظیر داده کثیف، نرخ ریزش کم، پنهان ماندن رویداد ریزش و غیره را به همراه دارد. روش‌های پیش‌بینی ریزش مشتریان به طور گسترده بر پایه روش‌های طبقه‌بندی<sup>۹۱</sup> یادگیری ماشین انجام شده‌اند. در عملکرد این نوع طبقه‌بندی‌ها، با مشکل‌هایی نظیر ابعاد گسترده مجموعه داده‌ها<sup>۹۲</sup> و نامتوازن بودن آنها که مانع جهت پیش‌بینی دقیق است، روبرو هستیم (لئون و سیلو و تباک، ۲۰۲۲).

<sup>۹۱</sup>. Classification

<sup>۹۲</sup>. Dataset

در پیش‌بینی ریزش معمولاً طبقه‌بندی دودویی<sup>۹۳</sup> انجام می‌شود که ریزش‌کننده‌ها یک گروه کوچک و اقلیت را تشکیل می‌دهند و غیرریزش‌کننده‌ها اکثریت را تشکیل می‌دهند. بنابراین معمولاً مدل‌های یادگیری ماشین به علت کم‌بودن تعداد ریزش‌کننده‌ها تمایل دارند که همه مشتریان را غیرریزش‌کننده تشخیص دهند. اما این کار ارزشی ندارد و در عمل نتیجه خوبی حاصل نمی‌شود (آخر، ۲۰۲۲).

روش‌های گروهی<sup>۹۴</sup> نتایج بسیار خوبی را در مدیریت مجموعه داده‌های متعادل در پیش‌بینی ریزش نشان می‌دهد. علاوه بر این، روش‌های گروهی به طور گسترده در مدل‌های پیش‌بینی ریزش استفاده می‌شود. استفاده از این روش‌ها دقیق و ساده است و برای بهره‌برداری از مدل‌های پیچیده با قدرت محاسباتی کم، بسیار مناسب هستند.

## (۶) پیشنهاد تجربی

در این پژوهش ۱۴ مقاله در دامنه موضوعی مورد مطالعه، بررسی شده و پس از بررسی مجموعه داده‌ها و شاخص‌های ارزیابی استفاده شده در آنها، به یک جمع‌بندی برای مدل پیشنهادی رسیده است. جدول ۱ کارهای پیشین بررسی شده را معرفی می‌کند.

### جدول ۱. خلاصه مقالات بررسی شده

منابع	روش‌های ارزیابی	دقت	صنعت	روش‌های پیش‌بینی	سال
(هدیاس و ماتو و پیلای و زژول، ۲۰۱۷)	Accuracy	۷۰ درصد	شرکت اشتراک دهی	Deep Feed-Forward Networks	۲۰۱۷
(ژانگ و لی و مو و تانگ، ۲۰۱۸)	Accuracy, Precision, Recall, F1-Score, and AUC	۷۹.۱ درصد	مخابرات	Deep ANN, Machine Learning Algorithms	۲۰۱۸
(مالدونادو و لوپیز و ورتی، ۲۰۲۰)	Accuracy, AUC, Precision, Recall, F1-Score	۸۲ درصد	بیمه	Deep and Shallow Learning	۲۰۲۰
(کالردا و اکراسدوتیر و باستز، ۲۰۲۰)	Area Under Curve of ROC(AUC) and Complexity	۹۲ درصد	مخابرات	Transfer Learning of Ensemble	۲۰۲۰
(سی و یانگ و نیو و سو و تاسی و ژنگ، ۲۰۲۰)	Area Under Curve of ROC(AUC)	۸۵ درصد	مخابرات	Ensemble Algorithm	۲۰۲۰
(دویتروسو، ۲۰۲۱)	Accuracy and Precision of Classification	۸۱ درصد	مخابرات	Begging and Neural Network	۲۰۲۱
(کریستی، ۲۰۲۱)	Accuracy, Cost, Profit	۸۵ درصد	مخابرات	Profit Tree	۲۰۲۱
(لی و چونگ و فنگ و مو، ۲۰۲۱)	AUC, EMPC	۹۰ درصد	مخابرات	Minimax Probability Machines	۲۰۲۱
(سلوریا و پیانهریت و جونیور، ۲۰۲۱)	AUC, Tenlift AUPR	۸۴ درصد	مخابرات	Similarity Forests	۲۰۲۱
(جین و یاداو و مانو، ۲۰۲۲)	Accuracy, Kappa, Recall, etc.	۵۹.۲۴ درصد	بانک	Cross-Company Just-in-time Approach	۲۰۲۲
(حسینی و شرنجنی و اکبرآبادی، ۲۰۲۲)	AUC	۸۲ درصد	بانک	Multi-objective-ant Colony Optimization	۲۰۲۲
(مستوزلا، ۲۰۲۲)	Top Decile Lift	۷۵ درصد	بانک	Graph Theory	۲۰۲۲
(هارادا، ۲۰۲۲)	G means and AUC	۶۰ درصد	بانک	Boosted-Stacked Learners and Bagged-Stacked Learners	۲۰۲۲
(جین و خومتا و استریستوا، ۲۰۲۲)	Accuracy, Kappa, MAE, Coverage Case, RMSE	۷۱ درصد	بانک	Logistic Regression and Logit Boost	۲۰۲۲

<sup>۹۳</sup>. Binary

<sup>۹۴</sup>. Ensemble Methods

همانطور که بررسی پژوهش‌های پیشین نشان می‌دهد، تأکید مقالات در یک یا دو روش از روش‌های استخراج ویژگی است، آنها همچنین همزمان روش‌های یادگیری ماشین و روش یادگیری عمیق را در استخراج ویژگی درنظر نگرفته‌اند. مقالات اخیر نشان می‌دهد که معیارهای ارزیابی برای ایجاد یک سیستم تشخیص ریزش کافی نیستند. در طبقه‌بندی ریزش مشتریان، همیشه باید مدل‌ها را با عملکرد خود نسبت به ماهیت نامتعادل مجموعه داده‌ها مقایسه کرد (لی و ژانگ و مائو، ۲۰۱۸). از آنجاکه مشکل ریزش به دلیل عدم دسترسی به سابقه داده‌های ریزش گر بسیار نامتعادل است، بنابراین لازم است مدل‌های طبقه‌بندی ریزش با کلیه معیارهای مرتبط ارزیابی شوند.

## (۷) طرح مسئله و راه حل پیشنهادی

زبان پایتون با مجموعه‌ای از کتابخانه‌های علم داده و یادگیری ماشین عرضه می‌شود که می‌توان از آنها برای پیش‌بینی براساس ویژگی یا ویژگی‌های مختلف یک مجموعه داده استفاده کرد. این زبان یکی از پرکاربردترین زبان‌های برنامه‌نویسی برای تجزیه و تحلیل داده‌های مالی است که دارای کتابخانه‌های مفید و عملکرد داخلی فراوانی است. در این مقاله به بررسی مشتریان یک بانک پرداخته شده است و نتایج حاصل از بررسی نشان می‌دهد که چگونه یک بانک می‌تواند ریزش مشتری را بر اساس ویژگی‌های مختلف مشتری مانند سن، جنسیت، جغرافیا و موارد دیگر پیش‌بینی کند. کتابخانه SCIKIT-LEARN پایتون یکی از این ابزارها می‌باشد و در این مقاله از این کتابخانه برای پیش‌بینی ریزش مشتری استفاده شده است.

## (۸) فاز اول (تحلیل کسب و کار)

فاز اول شناخت کسب و کار و مطالعه بر روی عواملی است که در آن نوع کسب و کار مورد بررسی به فرآیند پیش‌بینی ریزش کمک می‌کند. لازم به ذکر است شاخص‌هایی که در یک بانک بر روی ریزش تاثیرگذار هستند با شاخص‌های یک سازمان مالی و مخابراتی متفاوت هستند. از این رو با استفاده از جلسه‌های مصاحبه و روش‌های طوفان فکری و موجودیت انواع داده در سازمان، به جمع‌آوری شاخص‌های موثر و داده‌های مربوط به آنها پرداخته خواهد شد. به علاوه در این فاز آستانه تحمل ریزش شرکت یعنی درصد احتمالی که شرکت برای یک مشتری ریزش‌کننده بالقوه تعیین می‌کند، تعریف می‌شود.

مجموعه داده‌ای که برای توسعه یک مدل پیش‌بینی ریزش مشتری برای یک بانک درنظر گرفته شده است، دارای ۱۴ ستون است که به عنوان ویژگی یا متغیر شناخته می‌شود. با توجه به شکل ۱، ۱۳ ستون اول متغیر مستقل هستند، در حالیکه ستون آخر، متغیر وابسته است که دارای مقدار باینری ۰ یا ۱ است.

RowNum	Customer	Surname	CreditScore	Geography	Gender	Age	Tenure	Balance	NumOfPr	HasCrCard	IsActiveM	Estimated	Exited	
1	1	15634602	Hargrave	619	France	Female	42	2	0	1	1	1	101348.9	1
2	2	15647311	Hill	608	Spain	Female	41	1	83807.86	1	0	1	112542.6	0
3	3	15619304	Onio	502	France	Female	42	8	159660.8	3	1	0	113931.6	1
4	4	15701354	Boni	699	France	Female	39	1	0	2	0	0	93826.63	0
5	5	15737888	Mitchell	850	Spain	Female	43	2	125510.8	1	1	1	79084.1	0
6	6	15574012	Chu	645	Spain	Male	44	8	113755.8	2	1	0	149756.7	1
7	7	15592531	Bartlett	822	France	Male	50	7	0	2	1	1	10062.8	0
8	8	15656148	Obinna	376	Germany	Female	29	4	115046.7	4	1	0	119346.9	1
9	9	15792365	He	501	France	Male	44	4	142051.1	2	0	1	74940.5	0
10	10	15592389	H?	684	France	Male	27	2	134603.9	1	1	1	71725.73	0
11	11	15767821	Bearce	528	France	Male	31	6	102016.7	2	0	0	80181.12	0
12	12	15737173	Andrews	497	Spain	Male	24	3	0	2	1	0	76390.01	0
13	13	15632264	Kay	476	France	Female	34	10	0	2	1	0	26260.98	0
14	14	15691483	Chin	549	France	Female	25	5	0	2	0	0	190857.8	0
15	15	15600882	Scott	635	Spain	Female	35	7	0	2	1	1	65951.65	0
16	16	15643966	Goforth	616	Germany	Male	45	3	143129.4	2	0	1	64327.26	0
17	17	15737452	Romeo	653	Germany	Male	58	1	132602.9	1	1	0	5097.67	1
18	18	15788218	Henderso	549	Spain	Female	24	9	0	2	1	1	14406.41	0
19	19	15661507	Muldrow	587	Spain	Male	45	6	0	1	0	0	158684.8	0
20	20	15568982	Hao	726	France	Female	24	6	0	2	1	1	54724.03	0

شکل ۱. نموداری برای نمونه

در شکل ۱ ، مقدار ۱ به حالتی اشاره دارد که مشتری پس از ۶ ماه بانک را ترک کرده است و مقدار ۰ موردنی است که مشتری بعد از ۶ ماه بانک را ترک نکرده است. این به عنوان یک مشکل طبقه‌بندی باینری شناخته می‌شود که در آن شما فقط دو مقدار ممکن برای متغیر وابسته دارید. در این مورد، مشتری یا پس از ۶ ماه بانک را ترک می‌کند یا ترک نمی‌کند. ذکر این نکته حائز اهمیت است که داده‌های متغیرهای مستقل ۶ ماه قبل از داده‌های متغیر وابسته جمع‌آوری شده است زیرا وظیفه توسعه یک مدل یادگیری ماشینی است که بتواند پیش‌بینی کند که آیا مشتری پس از ۶ ماه بانک را ترک می‌کند یا خیر. برای حل این مشکل می‌توان از الگوریتم‌های طبقه‌بندی مدل‌های یادگیری ماشین استفاده کرد.

## (۹) فاز دوم (وارد کردن کتابخانه‌ها)

در این فاز کتابخانه‌های Numpy، pandas، Matplotlib، Mordniyaz است.

## (۱۰) فاز سوم (انتخاب ویژگی)

بعد از جمع‌آوری مجموعه داده‌های موردنیاز براساس ویژگی‌های کلیدی و نوع صنعت، در این فاز به انجام پیش‌پردازش‌های اولیه از جمله حذف نویزها و داده‌های فراموش شده و تمیز کردن مجموعه داده‌ها پرداخته می‌شود. با توجه به شکل ۱ دارای مجموعه ویژگی‌های زیر هستیم:

Row Number: مربوط به شماره رکورد یا ردیف است و تأثیری بر خروجی ندارد و این ستون حذف خواهد شد.

Customer ID: حاوی مقادیر تصادفی است و تأثیری بر خروج مشتری از بانک ندارد و این ستون حذف خواهد شد.

Surname: نام خانوادگی مشتری تأثیری بر تصمیم او برای ترک بانک ندارد و این ستون نیز حذف خواهد شد.

- Credit Score: میزان امتیاز مشتری در اعتبارات می‌تواند بر روی ریزش مشتری تأثیر بگذارد زیرا مشتری با امتیاز اعتباری کمتر بانک را ترک می‌کند.
- Geography: موقعیت یک مشتری می‌تواند بر تصمیم او برای ترک بانک تأثیر بگذارد.
- Gender: تاثیر جنسیت در خروج مشتری از بانک تأثیرگذار است.
- Age: این ویژگی با ریزش مشتری مرتبط است زیرا مشتریان مسن‌تر، کمتر از افراد جوان‌تر بانک خود را ترک یا عوض می‌کنند.
- Tenure: این ویژگی به تعداد سال‌هایی اشاره دارد که یک فرد مشتری بانک بوده است. به طور معمول، مشتریان مسن‌تر وفادارتر هستند و کمتر بانک را ترک می‌کنند.
- Balance: یک شاخص بسیار خوب از ریزش مشتری است زیرا افرادی که موجودی بیشتری در حساب‌های خود دارند، در مقایسه با افرادی که موجودی کمتری دارند، کمتر بانک را ترک می‌کنند.
- NumOfProducts: به تعداد محصولاتی که مشتری از طریق بانک خریداری کرده است، اشاره دارد.
- HasCrCard: این ویژگی بیانگر این موضوع است که آیا مشتری کارت اعتباری دارد یا خیر. این ستون نیز مرتبط است زیرا افرادی که کارت اعتباری دارند، کمتر بانک را ترک می‌کنند.
- IsActiveMember: مشتریان فعال کمتر بانک را ترک می‌کنند بنابراین این ویژگی در تعیین ریزش مشتری کمک کننده است.
- Estimated Salary: این ویژگی همانند موجودی، افرادی که حقوق کمتری دارند در مقایسه با افرادی که حقوق بالاتری دارند، احتمال بیشتری دارد بانک را ترک کنند.
- Exited: در ارزیابی ریزش مشتری این ویژگی لحاظ خواهد شد.
- پس از مشاهده دقیق ویژگی‌ها، ستون‌های Row Number و Customer ID از مجموعه ویژگی‌ها حذف می‌شوند و تمام ستون‌های باقی‌مانده به یک شکل به ریزش مشتری کمک می‌کنند.

## (۱۱) فاز چهارم (تبديلداده‌ها)

الگوریتم‌های یادگیری ماشین با داده‌های عددی، کارآیی بسیار بهتری را ارائه می‌دهند. درمجموع داده‌های مورد مطالعه، دو ستون دسته‌بندی داریم: جغرافیا و جنسیت. این دو ستون حاوی داده‌ها در قالب متغیر هستند و باید آنها به ستون‌های عددی تبدیل شوند. یکی از راه‌های تبدیل ستون‌های دسته‌بندی به ستون‌های عددی این است که می‌توان هر دسته را با یک عدد جایگزین کرد. به عنوان مثال: در ستون جنسیت، زن را می‌توان با مقدار ۰ و مرد را با مقدار ۱ جایگزین کرد یا بالعکس. این برای ستون‌هایی با دو دسته کار می‌کند.

برای ستونی مانند جغرافیا با سه دسته یا بیشتر، می‌توان از مقادیر ۰ و ۱ و ۲ برای سه کشور فرانسه، آلمان و اسپانیا استفاده کرد. لذا اگر این کار انجام گیرد، الگوریتم‌های یادگیری ماشین فرض می‌کنند که یک رابطه ترتیبی بین این سه کشور وجود دارد. به عبارت دیگر، الگوریتم فرض می‌کند که ۲ بزرگ‌تر از ۱ و ۰ است که درواقع از نظر کشورهای

زیربنایی که اعداد نشان می‌دهند، این طور نیست. یک راه بهتر برای تبدیل ستون‌های دسته‌بندی به ستون‌های عددی، استفاده از one-hot encoding است. در این فرآیند دسته‌ها فرانسه، آلمان، اسپانیا هستند و آنها به عنوان یک ستون مجزا در نظر گرفته شده‌اند و در هر ستون از ۱ برای تعیین اینکه دسته برای ردیف فعلی وجود دارد، استفاده شده‌است و در غیر این صورت از ۰ به عنوان جایگزین استفاده شده‌است.

### (۱۲) فاز پنجم (پیش‌پردازش داده‌ها)

در فرآیندهای داده‌کاوی مانند طبقه‌بندی و خوشه‌بندی، نیاز داریم تا داده‌ها برای الگوریتم آماده شوند. زیرا معمولاً نمی‌توان داده‌ها را به صورت خام به الگوریتم‌های داده‌کاوی و یادگیری ماشین تزریق کرد. از آنجاییکه داده‌ها معمولاً از منابعی تهیه می‌شوند که این منابع بدون توجه به فرآیندهای داده‌کاوی، داده‌ها را تولید یا نگهداری کرده‌اند، نیاز است داده‌ها با توجه به شرایط و مسئله، به داده‌های مناسب جهت تزریق به الگوریتم‌های داده‌کاوی آماده شوند. برای آماده‌سازی داده‌ها، نیاز است تا آنها را از شکل و حالت اولیه خارج کرده و به شکلی که برای الگوریتم مناسب باشد تبدیل کنیم. همچنین داده‌های موجود معمولاً دارای زواید مختلفی هستند که ممکن است الگوریتم را دچار خطا کنند. در داده‌کاوی نیاز است تا داده‌های اضافی که به مسئله و الگوریتم کمکی نمی‌کنند، حذف گردد. در این مرحله از پیش‌بینی، داده‌ها آماده است و می‌توان مدل یادگیری ماشینی را برای آموزش آن در نظر بگیریم. در ابتدا باید متغیری که پیش‌بینی می‌شود از مجموعه داده‌ها جدا گردد. این فرآیند شامل تمام ستون‌ها به جز ستونی است که باید پیش‌بینی شود. ستون Exited بر جسب داده‌ها را مشخص می‌کند بنابراین در ادامه عملکرد مدل یادگیری ماشینی با این ستون ارزیابی می‌گردد. برای پیاده‌سازی مدل، داده‌ها به یک مجموعه آموزشی و آزمایشی تقسیم شده‌است. مجموعه آموزشی حاوی داده‌هایی است که برای آموزش مدل یادگیری ماشین استفاده می‌شود و مجموعه آزمایش برای ارزیابی اینکه مدل معرفی شده چقدر خوب است، استفاده خواهد شد. ۲۰ درصد از داده‌ها را برای مجموعه آزمایش و از ۸۰ درصد باقیمانده برای مجموعه آموزشی استفاده شده‌است.

### (۱۳) فاز ششم (آموزش الگوریتم یادگیری ماشین)

در این مرحله از یک الگوریتم یادگیری ماشینی برای پیش‌بینی، استفاده شده‌است که الگوهای روندهای را در داده‌های آموزشی شناسایی می‌کند. این مرحله به آموزش الگوریتم معروف است.

ویژگی‌ها و خروجی صحیح به الگوریتم داده می‌شود و براساس آن داده‌ها، الگوریتم یاد خواهد گرفت که ارتباط بین ویژگی‌ها و خروجی‌ها را بیابد. پس از آموزش الگوریتم، از آن برای پیش‌بینی داده‌های جدید استفاده شده‌است. چندین الگوریتم یادگیری ماشین وجود دارد که می‌توان از آنها برای انجام چنین پیش‌بینی‌هایی استفاده کرد. در این مقاله از الگوریتم جنگل تصادفی<sup>۹۵</sup> استفاده شده‌است که در ادامه به آن پرداخته خواهد شد.

### (۱۴) الگوریتم جنگل تصادفی<sup>۹۶</sup>

جنگل تصادفی یک روش یادگیری ترکیبی برای طبقه‌بندی داده‌ها می‌باشد که از تعداد زیادی درخت تصمیم در زمان آموزش

<sup>۹۵</sup>. Random forest

<sup>۹۶</sup>. Random forest

تشکیل شده است و خروجی این الگوریتم برای طبقه‌بندی مجموعه‌ای از داده‌ها مورد استفاده قرار می‌گیرد. در الگوریتم جنگل تصادفی درواقع مجموعه‌ای از درخت‌های تصمیم، با هم یک جنگل را تولید می‌کنند و این جنگل می‌تواند تصمیم‌های بهتری را نسبت به یک درخت اتخاذ نماید. در الگوریتم جنگل تصادفی به هر کدام از درخت‌ها، یک زیرمجموعه‌ای از داده‌ها تزریق می‌شود. درخت‌ها می‌توانند تصمیم بگیرند و مدل طبقه‌بندی خود را بسازند. در هنگام پیش‌بینی، هر کدام از این الگوریتم‌های یادگرفته شده، یک نتیجه را پیش‌بینی می‌کنند. در نهایت الگوریتم جنگل تصادفی، می‌تواند با استفاده از رای گیری، آن طبقه‌ای را که بیشترین رای را آورده است، انتخاب کرده و به عنوان طبقه نهایی جهت انجام عملیات طبقه‌بندی قرار دهد. همچنین جنگل‌های تصادفی برای درختان تصمیمی که در فرآیند آموزش دچار بیش‌برازش می‌شوند، مناسب هستند و جنگل تصادفی معمولاً بهتر از درخت تصمیم است اما این بهبود عملکرد تا حدی به نوع داده هم بستگی دارد (رائو، ۲۰۱۶).

## ۱۵) نحوه عملکرد الگوریتم جنگل تصادفی

نحوه کار کردن الگوریتم جنگل تصادفی به شرح زیر است:

- ۱- ابتدا با انتخاب نمونه‌های تصادفی از یک مجموعه داده الگوریتم شروع می‌شود.
  - ۲- این الگوریتم برای هر نمونه، یک درخت تصمیم گیری ایجاد می‌کند. سپس نتیجه پیش‌بینی از هر درخت تصمیم به دست می‌آید.
  - ۳- رای گیری برای هر نتیجه پیش‌بینی شده انجام می‌گیرد.
  - ۴- بیشترین نتیجه پیش‌بینی، به عنوان پیش‌بینی نهایی انتخاب می‌گردد.
- در شکل ۲ کد الگوریتم جنگل تصادفی نیز قابل مشاهده است.

```

Precondition: A training set  $S := (x_1, y_1), \dots, (x_n, y_n)$ , features  $F$ , and number
of trees in forest  $B$ .
1 function RANDOMFOREST( $S, F$ )
2    $H \leftarrow \emptyset$ 
3   for  $i \in 1, \dots, B$  do
4      $S^{(i)} \leftarrow$  A bootstrap sample from  $S$ 
5      $h_i \leftarrow$  RANDOMIZEDTREELEARN( $S^{(i)}, F$ )
6      $H \leftarrow H \cup \{h_i\}$ 
7   end for
8   return  $H$ 
9 end function
10 function RANDOMIZEDTREELEARN( $S, F$ )
11   At each node:
12      $f \leftarrow$  very small subset of  $F$ 
13     Split on best feature in  $f$ 
14   return The learned tree
15 end function

```

شکل ۲. کد الگوریتم جنگل تصادفی (لی و چونک و فنگ و مو، ۲۰۲۱)

## ۱۶) الگوریتم جایا <sup>۹۷</sup>

یکی از الگوریتم‌های فرآیندکاری مناسبی که برای حل مسئله‌های بهینه‌سازی محدود و نامحدود استفاده می‌شود، الگوریتم بهینه‌سازی جایا است. الگوریتم جایا، در فرآیند جستجو سعی می‌کند با فرار از بدترین راه حل، با اجتناب از شکست، برای

<sup>۹۷</sup>. Jaya

یافتن راه حل های بهینه به بهینه ترین راه حل ممکن، نزدیک تر شود. الگوریتم جایا روشنی ساده و جدید به منظور حل مسائل بهینه سازی می باشد. این الگوریتم بر این اصل استوار است که برای رسیدن به بهترین جواب باید راه حل های موجود در هر تکرار به سمت بهترین راه حل ارائه شده حرکت کرده و از بدترین راه حل در همان تکرار نیز دور شوند. از مزایای الگوریتم جایا می توان به سادگی، عدم نیاز به هیچ پارامتر کنترلی و سرعت آن اشاره کرد. به بیان دیگر الگوریتم جایا، الگوریتم فر ابتکاری است که با استفاده از مناسب ترین مفاهیم تحریک می شود و با اجتناب از راه حل غیربهینه، به سمت راه حل های بهینه می روند. در الگوریتم جایاتابع  $(x)$  تابع هدف مسئله بوده و الگوریتم جایا قصد یافتن مینیمم (ماکزیمم) آن را دارد. در هر تکرار  $k$ ، الگوریتم جایا دارای  $n$  متغیر تصمیم گیری و  $N_{param}$  راه حل پیشنهادی است.

**مراحل الگوریتم جایا به شرح زیر است:**

۱- پارامترهای الگوریتم جایا مانند اندازه جمعیت  $N$  و حداقل تعداد تکرار  $K_{max}$  باید در تمام مسائل بهینه سازی مقداردهی اولیه شوند. داده های تعریف شده باید از مجموعه داده های مسئله استخراج شوند و همچنین تابع هدف و راه حل پیشنهادی شده معمولا در این مرحله بایستی مشخص گردد. تعریف داده های ورودی و مشخص شدن حد بالا و حد پایین مجموعه داده ها باید در این مرحله صورت پذیرد.

۲- در این مرحله تشکیل جمعیت اولیه صورت می پذیرد. براساس داده های موجود در مرحله اول، یک جمعیت اولیه به صورت تصادفی به گونه ای که محدودیت ها رعایت شود، تشکیل می گردد که جامعه تشکیل شده شامل  $N$  راه  $d$  بعدی است.

۳- محدودیت های مسئله در این مرحله مورد بررسی قرار می گیرد و بهترین و بدترین راه حل ها در این مرحله مشخص می شود.

۴- الگوریتم جایا به صورت تصادفی هر متغیر تصمیم موجود در هر راه حل را در هر تکرار تغییر می دهد. به عبارت دیگر تابع هدف مسئله مشخص می شود.

۵- برای استفاده از الگوریتم مورد نظر می باشد بدترین و بهترین جواب مشخص شود. بنابراین هدف الگوریتم جایا با استفاده از شرایط فوق تحقق می یابد.

۶- الگوریتم جایا روی مجموعه جواب های موجود باید اعمال گردد تا در مجموعه جواب های محاسبه شده، بهبود حاصل گردد.

۷- پس از بهرو رسانی مجدد جواب ها، شماره تکرار یک واحد افزایش می یابد و شرط همگرایی بررسی می شود. اگر شرط همگرایی در الگوریتم برآورده شده بود این قاعده پایان می یابد و بهترین جواب چاپ می شود در غیر این صورت مجدد مرحله ۵ مورد بررسی قرار می گیرد. در شکل ۳ کد الگوریتم جایا نیز قابل مشاهده است.

```

1: Initialize input Jaya parameters:  $r_1, r_2, X_j^{LB}, X_j^{UB}, N, d, k_{max}$ 
2: ----- Initializing the initial population -----
3: For  $i = 1:1:N$  Do /* Each solution */
4:   For  $j = 1:1:d$  Do /* Each variable */
5:     Calculate:  $X_{i,j} = X_j^{LB} + (X_j^{UB} - X_j^{LB}) \times U(0,1)$ 
6: Calculate:  $f(X_i)$ 
7: ----- Define the best and worst solutions in the population -----
8:  $itr(k) = 1$ 
9: while ( $k < k_{max}$ ) do
10:   Determine the best solution in the population ( $X_{best}$ )
11:   Determine the best solution in the population ( $X_{worst}$ )
12: For  $i = 1:1:N$  Do
13:   For  $j = 1:1:d$  Do
14:     Set  $r_1 \in (0,1)$ 
15:     Set  $r_2 \in (0,1)$ 
16: Calculate:  $X'_{i,j} = X_{i,j} + r_1 \times (X_{best,j} - [X_{i,j}]) - r_2 \times (X_{worst,j} - [X_{i,j}])$ 
17: End For
18: If  $f(X'_i) \leq f(X_i)$  then
19:    $X'_i = X_i$  (update process)
20: End If
21: End For
22:  $k = k + 1$ 
23: End while

```

شکل ۳. کد الگوریتم جایا (ویلت، ۲۰۲۱).

با توجه به الگوریتم جنگل تصادفی نتایج حاصل از ارزیابی رضایت‌بخش نبود بنابراین روش پیشنهادی ترکیبی از الگوریتم جنگل تصادفی و الگوریتم جایا می‌باشد که مراحل آن به شرح زیر است:

**مرحله اول مقداردهی اولیه:** در این مرحله یکتابع توزیع به صورت تصادفی برای تعیین پارامترهای الگوریتم *Jaya* مانند اندازه جمعیت  $N$  که بیانگر تعداد راه حل‌های ممکن است و حداکثر تعداد تکرار الگوریتم که با  $kmax$  نمایش داده می‌شود، تعریف می‌گردد. همچنین مجموعه پارامترهای الگوریتم جنگل تصادفی تعریف می‌گردد.

**مرحله دوم مشخص‌سازی تابع هدف مناسب:** بهترین مقدار برای تابع هدف در مرحله  $i^{th}$  به ازای داده ورودی  $x_i$  به صورت  $f(i)$  تعریف می‌گردد. به دلیل اینکه الگوریتم جایا هر کدام از راه حل‌های انتخابی  $x_i$  را برای طراحی درست طبقه‌بندی الگوریتم جنگل تصادفی با جایا بررسی می‌کند، انتخاب صحیح تابع هدف مناسب جز ضروریات است، که تعداد نمونه‌های مشاهده شده در فرآیند تست است و  $Error(p)$  برای بدست آوردن میزان خطأ مقدار واقعی از مقدار برآورده شده، مورد استفاده قرار می‌گیرد.

در این مقاله به دقت طبقه‌بندی و تعداد ویژگی‌های انتخاب شده، به عنوان دو پارامتر اساسی در تعریف تابع هدف مناسب می‌توان اشاره کرد. بنابراین انتخاب راه حل با بالاترین دقت تصمیم‌گیری و کمترین تعداد ابعاد، به عنوان دو پارامتر برای برآورد بهترین تابع هدف تعریف می‌شود و میزان مناسب بودن تابع هدف به کمک رابطه (۱) ارزیابی می‌گردد:

$$finess(i) = \frac{\sum_{i=1}^m (Error(p))^2}{m}. p == 1.2 \dots m \quad (رابطه ۱)$$

**مرحله سوم مشخص‌سازی بهترین و بدترین کاندیدها:** بعد از ارزیابی تابع هدف مناسب، بهترین و بدترین کاندیدها که به ترتیب با  $x_{best}$  و  $x_{worst}$  تعریف می‌گردد، که این مقدارها از طریق ماکزیمم و مینیمم مقداری که تابع هدف محاسبه کرده است، تعریف شده است.

**مرحله چهارم بهبود راه حل:** در این مرحله بهترین و بدترین راه حل های به دست آمده از مرحله قبل ذخیره می شوند و سایر راه حل های به دست آمده به روزرسانی می شوند و مجدد تابع هدف مناسب به وسیله مقادیر جدید به دست آمده، تخمین زده می شود.

**مرحله پنجم برسی راه حل:** اگر مقدار تابع هدف به دست آمده در مرحله جدید بهتر از مرحله قبلی باشد، مقدار جدید به دست آمده جایگزین مقدار قبلی می شود در غیر این صورت الگوریتم برای بار دیگر تکرار می شود.

**مرحله ششم:** کلیه مرحله های ۲ تا ۵ مدامی که تعداد دفعات تکرار الگوریتم برابر  $k_{max}$  شود، انجام می گردد.

## (۱۷) فاز هفتم (ارزیابی مدل)

بعد از آموزش، ارزیابی صورت می گیرد تا بررسی شود که الگوریتم انتخابی در پیش‌بینی ریزش مشتری چقدر خوب عمل می کند. برای ارزیابی عملکرد یک الگوریتم طبقه‌بندی، متداول‌ترین معیارهای مورداستفاده عبارتنداز: دقت<sup>۹۸</sup>، یادآوری<sup>۹۹</sup> و صحت<sup>۱۰۰</sup>. در معیار دقت حداکثر مقدار این معیار یک و یا ۱۰۰ درصد است و حداقل مقدار آن صفر است و هرچه مواردی که برنامه به غلط پیش‌بینی کرده است که به آن مثبت کاذب می گویند نسبت به پیش‌بینی های درست که به آن مثبت کاذب است می گویند بیشتر باشد، مقدار یادآوری کمتر خواهد شد و طبق رابطه (۲) قابل محاسبه است.

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (\text{رابطه } 2)$$

که در آن TP مثبت واقعی و FP مثبت کاذب است.

در معیار یادآوری حداکثر مقدار این معیار یک و یا ۱۰۰ درصد است و حداقل مقدار آن صفر است و هرچه مواردی که برنامه پیش‌بینی نکرده است که به آن منفی کاذب<sup>102</sup> می گویند نسبت به پیش‌بینی های درست که به آن مثبت واقعی می گویند بیشتر باشد، مقدار یادآوری کمتر خواهد شد و طبق رابطه (۳) قابل محاسبه است.

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (\text{رابطه } 3)$$

که در آن TP مثبت واقعی و FN منفی کاذب است.

در معیار صحت تعداد مواردی که درست پیش‌بینی شده است که به آن مثبت واقعی می گویند بر تعداد کل پیش-بینی هایی که انجام شده است، تقسیم می گردد و طبق رابطه (۴) قابل محاسبه است.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \quad (\text{رابطه } 4)$$

که در آن TP مثبت واقعی، TN منفی واقعی<sup>۱۰۳</sup>، FP مثبت کاذب و FN منفی کاذب است.

<sup>98</sup>. Precision

<sup>99</sup>. Recall

<sup>100</sup>. Accuracy

<sup>101</sup>. True Positive

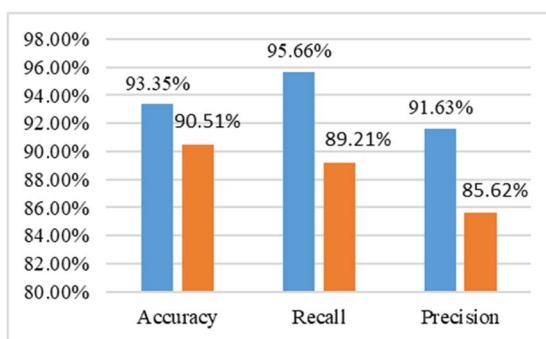
<sup>102</sup>. False Negative

<sup>103</sup>. True Negative

در کتابخانه scikit-learn پایتون، می‌توانیم از توابع داخلی برای یافتن همه این مقادیر استفاده کنیم و اگر مدل کارآیی لازم را نداشت، دوباره به فاز پنج برمی‌گردیم و تنظیمات پارامترهای اولیه بر روی مدل قبلی برای رسیدن به نتیجه مطلوب تغییر پیدا خواهد کرد. نتایج حاصل از مقاله به ترتیب در جدول ۲ و شکل ۴ آورده شده‌است.

**جدول ۲. نتایج به دست آمده استفاده از الگوریتم جنگل تصادفی و روش پیشنهادی**

	Accuracy	Recall	Precision
جنگل تصادفی	% ۹۰.۵۱	% ۸۹.۲۱	% ۸۰.۶۲
مدل پیشنهادی	% ۹۳.۳۵	% ۹۵.۶۶	% ۹۱.۴۱

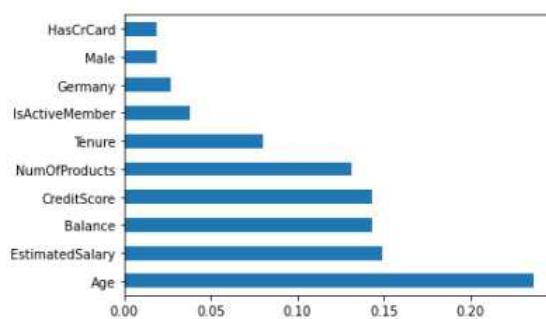


شکل ۴. مقایسه نتایج به دست آمده از الگوریتم جنگل تصادفی و روش پیشنهادی

همانطور که قابل ملاحظه است، نتایج حاصل از مدل پیشنهادی در مقاله به ترتیب در معیارهای Precision، Recall و Accuracy حدوداً به میزان ۳ درصد، ۶ درصد و ۷ درصد از الگوریتم جنگل تصادفی بالاتر می‌باشد.

#### (۱۸) فاز هشتم (ارزیابی ویژگی)

به عنوان آخرین مرحله در پیش‌بینی ریزش مشتری، بررسی می‌شود که کدام ویژگی مهمترین نقش را در شناسایی ریزش مشتری ایفا می‌کند. خوشبختانه طبقه‌بندی جنگل تصادفی<sup>۱۰۴</sup> دارای ویژگی با نام ویژگی‌های مهم<sup>۱۰۵</sup> است که حاوی اطلاعاتی درمورد مهمترین ویژگی‌های یک طبقه‌بندی معین است و خروجی آن به صورت شکل ۵ است.



شکل ۵. ارزیابی ویژگی‌های بررسی شده

<sup>104</sup>. Random Forest Classifier

<sup>105</sup>. Feature Importance

براساس این داده‌ها، ملاحظه می‌شود که ویژگی‌های سن، حقوق، دستمزد تخمینی مشتری و مانده‌حساب، به ترتیب بیشترین تأثیر را بر ریزش مشتری دارد.

## ۱۹) نتیجه‌گیری و پیشنهادات

با توجه به اهمیت حفظ مشتری در کسب‌وکارهای مختلف اعم از بانک‌ها، سازمان‌های مخابراتی، بیمه و حتی بازی‌های آنلاین، تحقیقات متعددی بر روی پیش‌بینی ریزش مشتریان و عوامل موثر بر روی آنها انجام شده است. در این تحقیق‌ها سعی شده است از راه‌های گوناگون از جمله داده موجود در ارتباط با مشتریان و نحوه تعامل مشتریان با سازمان و همچنین تعامل مشتریان با یکدیگر به پیش‌بینی دقیق ریزش مشتریان دست یابند.

نحوه انجام فرآیند پیش‌بینی ریزش مشتریان بسیار اهمیت دارد چرا که انتخاب نوع داده‌ها و نوع مدل یادگیری، به شدت دقت پیش‌بینی را تحت تاثیر قرار می‌دهد. این فرآیند با شناخت کسب‌وکار و عوامل موثر بر ریزش مشتری در آن صنعت آغاز می‌شود. پس از مهندسی ویژگی‌ها، انتخاب مدل یادگیری و ارزیابی آن، بهترین مدل انتخاب می‌شود و براساس آن مشتریان ریزش‌گر سازمان انتخاب خواهد گردید. در نهایت سازمان برای حفظ مشتریان ریزش‌گر، استراتژی‌های مختلفی اتخاذ می‌کند. پیش‌بینی ریزش مشتری برای ثبات مالی بلندمدت یک بانک بسیار مهم است.

در این مقاله، با موفقیت یک مدل یادگیری ماشین ایجاد شد که می‌تواند ریزش مشتری را با دقت ۹۳.۳۵ درصد پیش‌بینی کند. نتایج حاصل از مدل پیشنهادی در مقاله به ترتیب در معیارهای Precision، Recall و Accuracy حدوداً به میزان ۳ درصد، ۶ درصد و ۷ درصد از الگوریتم جنگل بالاتر می‌باشد. علاوه بر این، طبق بررسی‌های به عمل آمده در سازمان‌هایی که تعداد مشتریان زیادتر است و داده‌های مختلفی را در اختیار دارند، توانسته‌اند در پیش‌بینی ریزش مشتریان موفق‌تر عمل نمایند.

پیشنهاد می‌شود که برای توسعه تکنیک‌های داده‌کاوی در آینده از روش‌های مبتنی بر مشکل استفاده شود و بر پیش‌بینی نوع ریزش تمرکز گردد. علاوه بر این، می‌توان از مدل‌های ترکیبی استفاده نمود و آنها را با مدل‌های موجود مقایسه کرد. این امر به طراحی چند بعدی مجموعه داده‌های مشتری کمک می‌کند و به ابداع تکنیک‌های جدید مدیریت ریزش برای مجموعه داده‌های مختلف و مکان‌های جغرافیایی مختلف می‌انجامد. همچنین تصمیم‌گیری براساس تحلیل‌های ناشی از داده‌کاوی باعث می‌شود پیش‌بینی ریزش دقیق‌تر شود و بینشی ارزشمند به وجود آید.

## منابع

- A. Ahmed, A. Khan, S. H. Khan, A. Basit, I. U. Haq, and Y. S. Lee, “Transfer Learning and Meta Classification Based Deep Churn Prediction System for Telecom Industry,” pp. 1–10, 2022. <https://doi.org/10.1016/j.apmrv.2021.02.003>
- A. Amin., “Customer churn prediction in the telecommunication sector using a rough set approach,” Neurocomputing, vol. 237, 2017. <https://doi.org/10.1016/j.apmrv.2018.02.056>
- A. H. A. Kandel, “A comparative study of tree-based models for churn prediction: a case study in the telecommunication sector.” 2019. DOI:10.1007/s00170-013-5021-y
- B. Amin, F. Al-Obeidat, B. Shah, A. Adnan, J. Loo, and S. Anwar, “Customer churn prediction in telecommunication industry using data certainty,” J. Bus. Res., vol. 94, pp. 290–301, 2019. <https://doi.org/10.1016/j.amc.2005.01.081>
- Baran, R.R. and Strunk, D.P. *Principles of Customer Relationship Management*. Australia: Thomson Southwest., PP: 131-134, 2019. DOI: [https://10.1016/S0305-0548\(03\)00095-9](https://10.1016/S0305-0548(03)00095-9)
- Baliga, A. J., Chawla, V., Sunder M, V., & Kumar, R. *Barriers to service recovery in B2B markets: a TISM approach in the context of IT-based services*. Journal of Business & Industrial Marketing. 1(11), 202-226, 2021. DOI: [https://10.1016/S0305-0548\(03\)00095-9](https://10.1016/S0305-0548(03)00095-9)
- Chauhan, S.; Akhtar, A.; Gupta, A. *Customer experience in digital banking: A review and future research directions*. IJQSS 14, 311–348, 2022. <https://doi.org/10.1016/j.jmse.2020.10.001>

- Christy, A.J.; Umamakeswari, A.; Priyatharsini, L.; Neyaa, A. *RFM ranking-An effective approach to customer segmentation*. J. King. Saud. Univ. Sci., 33, 1251–1257, 2021. DOI: <https://doi.org/10.1016/j.japs.2012.04.041>
- De Lima Lemos, R.A.; Silva, T.C.; Tabak, B.M. *Propensity to customer churn in a financial institution: A machine learning approach*. Neural Comput. Appl., 1–18, 2022. (DOI): <https://doi.org/10.22059/IMJ.2016.61711>
- D. Spanoudes and T. Nguyen, "Deep Learning in Customer Churn Prediction: Unsupervised Feature Learning on Abstract Company Independent Feature Vectors," pp. 1–22, 2017 <https://doi.org/10.1016/j.fss.2011.03.003>
- Elena Dumitrescu et al., "Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects", European Journal of Operational Research, 2021. [https://doi.org/10.1016/S1874-8651\(10\)75329-4](https://doi.org/10.1016/S1874-8651(10)75329-4)
- E. S. Halibas, A. C. Matthew, I. G. Pillai, J. H. Reazol, E. G. Delvo, and L. B. Reazol, "Determining the intervening effects of exploratory data analysis and feature engineering in telecoms customer churn modelling," in 2018 4th MEC International Conference on Big Data and Smart City (ICBDSC), pp. 1–7, 2018. [https://doi.org/10.1016/S1874-8651\(10\)56951-4](https://doi.org/10.1016/S1874-8651(10)56951-4)
- G. Zhang, W. Li, T. Mo, and W. Tan, "Deep and Shallow Model for Insurance Churn Prediction Service," 2019, doi: 10.1109/SCC.2017.
- Hastie, Trevor. *The elements of statistical learning : data mining, inference, and prediction : with 200 full-color illustrations*. Springer. ISBN 0-387-95284-5. OCLC 46809224, 2022. doi.org/10.1016/S1874-8651(10)74596-4
- Hosseini, M.; Shahriari, S.; Akbarabadi, M. *Identifying multi-channel value co-creator groups in the banking industry*. J. Retail. Consum. Serv, 5, 102312, 2022. [https://doi.org/10.1016/S1874-8651\(10\)60853-4](https://doi.org/10.1016/S1874-8651(10)60853-4)
- iahou, X.; Harada, Y. B2C E-Commerce Customer Churn Prediction Based on K-Means and SVM. J. Theor. Appl. Electron. Commer. Res, 17, 458–475,2022. [https://doi.org/10.1016/S1874-8651\(10\)60874-4](https://doi.org/10.1016/S1874-8651(10)60874-4)
- Jain, H.; Yadav, G.; Manoov, R. Churn prediction and retention in banking, telecom and IT sectors using machine learning techniques. In Advances in Machine Learning and Computational Intelligence; Springer: Singapore, pp. 137–156, 2022. [https://doi.org/10.1016/S1874-8651\(10\)60001-4](https://doi.org/10.1016/S1874-8651(10)60001-4)
- Li, M.; Wang, Q.W.; Shen, Y.Z.; Zhu, T.Y. Customer relationship management analysis of outpatients in a Chinese infectious disease hospital using drug-proportion recency-frequency-monetary model. Int. J. Med. Inform, 147, 104373, 2021. [https://doi.org/10.1016/S1874-8651\(10\)60384-4](https://doi.org/10.1016/S1874-8651(10)60384-4)
- Li, Y.; Chu, X.Q.; Tian, D.; Feng, J.Y.; Mu, W.S. *Customer segmentation using K-means clustering and the adaptive*. Appl. Soft Comput, 113, 107924, 2021.
- Silveira, L.J.; Pinheiro, P.R.; Junior, L.S.D.M. *A Novel Model Structured on Predictive Churn Methods in a Banking Organization*. J. Risk Financ. Manag. 14, 481, 2022. [https://doi.org/10.1016/S1874-8651\(10\)60852-4](https://doi.org/10.1016/S1874-8651(10)60852-4)
- Matuszelański, K.; Kopczewska, K. *Customer Churn in Retail E-Commerce Business: Spatial and Machine Learning Approach*. J. Theor. Appl. Electron. Commer. Res, 17, 165–198,2022 . [https://doi.org/10.1016/S1874-8651\(10\)906874-4](https://doi.org/10.1016/S1874-8651(10)906874-4)
- Muneer, A.; Ali, R.F.; Alghamdi, A.; Taib, S.M.; Almaghthawi, A.; Ghaleb, E.A.A. *Predicting customers churning in banking industry: A machine learning approach*. Indones. J. Electr. Eng. Comput. Sci, 26, 539–549, 2022. [https://doi.org/10.1016/S1874-8651\(10\)60374-4](https://doi.org/10.1016/S1874-8651(10)60374-4)
- Piryonesi, S. M.; El-Diraby, T. E. "Data Analytics in Asset Management: Cost-Effective Prediction of the Pavement Condition Index". Journal of Infrastructure Systems. doi:[10.1061/\(ASCE\)IS.1943-55X.0000512](https://doi.org/10.1061/(ASCE)IS.1943-55X.0000512), 2022. [https://doi.org/10.1016/S1874-8651\(10\)90854-4](https://doi.org/10.1016/S1874-8651(10)90854-4)
- R. Rao, "Jaya: A simple and new optimization algorithm for solving constrained and unconstrained optimization problems," International Journal of Industrial Engineering Computations, vol. 7, no. 1, pp. 19-34, 2016. [https://doi.org/10.1016/S1874-8651\(10\)60874-4](https://doi.org/10.1016/S1874-8651(10)60874-4)
- S. Maldonado, J. López, and C. Vairetti, "Profit-based churn prediction based on Minimax Probability Machines," Eur. J. Oper. Res., vol. 284, no. 1, pp. 273–284, doi: 10.1016/j.ejor.2020.12.007, 2020 . [https://doi.org/10.1016/S1874-8651\(10\)60932-4](https://doi.org/10.1016/S1874-8651(10)60932-4)
- Sunday, K., Ocheja, P., Hussain, S., Oyelere, S., Samson, B., Agbo, F.: *Analyzing student performance in programming education using classification techniques*. Int. J. Emerg. Technol. Learn. (ijET) 15(2), 127–144, 2020. [https://doi.org/10.1016/S1874-8651\(10\)60037-4](https://doi.org/10.1016/S1874-8651(10)60037-4)
- T. Calzada-Infante, M. Óskarsdóttir, and B. Baesens, "Evaluation of customer behavior with temporal centrality metrics for churn prediction of prepaid contracts," Expert Syst. Appl, vol. 160, p. 113553, doi: 10.1016/j.eswa.2020.113553, 2020 . [https://doi.org/10.1016/S1874-8651\(10\)60035-4](https://doi.org/10.1016/S1874-8651(10)60035-4)
- Tékouabou, S.C.K.; Chabbar, I.; Toulni, H.; Cherif, W.; Silkan, H. Optimizing the early glaucoma detection from visual fields by combining preprocessing techniques and ensemble classifier with selection strategies. Expert Syst. Appl, 189, 115975, 2022. [https://doi.org/10.1016/S1874-8651\(10\)67841-4](https://doi.org/10.1016/S1874-8651(10)67841-4)
- Tien-Yu. Hsu, "Machine learning applied to stock index performance enhancement", Journal of Banking and Financial Technology, pp. 1-13, 2021. ) [https://doi.org/10.1016/S1874-8651\(10\)61324-4](https://doi.org/10.1016/S1874-8651(10)61324-4)
- U. Amin et al., "Just-in-time customer churn prediction in the telecommunication sector," J. Supercomput., vol. 76, no. 6, pp. 3924–3948, doi: 10.1007/s11227-017-2149-9, 2020 . [https://doi.org/10.1016/S1874-8651\(10\)62134-4](https://doi.org/10.1016/S1874-8651(10)62134-4)
- U. M. Kostić, M. I. Simić, and M. V Kostić, "Social Network Analysis and Churn Prediction in Telecommunications Using Graph Theory," Entropy, vol. 22, no. 7, p. 753, 2020 [https://doi.org/10.1016/S1874-8651\(10\)60001-4](https://doi.org/10.1016/S1874-8651(10)60001-4)
- U. Özmen, E. K. Aydoğán, Y. Delice, and M. D. Toksarı, "Churn prediction in Turkey's telecommunications sector: A proposed multiobjective-cost-sensitive ant colony optimization," Wiley Interdiscip. Rev. Data Min. Knowl. Discov., vol. 10, no. 1, p. e1338, doi: 10.1002/widm.1338, 2020. [https://doi.org/10.1016/S1874-8651\(10\)60001-4](https://doi.org/10.1016/S1874-8651(10)60001-4)
- Valluri, C.; Raju, S.; Patil, V.H. Customer determinants of used auto loan churn: Comparing predictive performance using machine learning techniques. J. Mark. Anal. 2021. [https://doi.org/10.1016/S1874-8651\(10\)60001-4](https://doi.org/10.1016/S1874-8651(10)60001-4)
- Veningston, K.; Rao, P.V.; Selvan, C.; Ronaldal, M. Investigation on Customer Churn Prediction Using Machine Learning Techniques. In Proceedings of International Conference on Data Science and Applications; Springer: Singapore, pp. 109–119, 2022. [https://doi.org/10.1016/S1874-8651\(10\)60001-4](https://doi.org/10.1016/S1874-8651(10)60001-4)
- W. Ahmed, H. Afzal, I. Siddiqi, M. F. Amjad, and K. Khurshid, "Exploring nested ensemble learners using overproduction and choose approach for churn prediction in telecom industry," Neural Comput. Appl., vol. 32, no. 8, pp. 3237–3251, doi: <https://doi.org/10.1007/s00521-018-3678-8, 2020>.
- W. Jain, A. Khunteta, and S. Srivastava, "Churn Prediction in Telecommunication using Logistic Regression and Logit Boost," Procedia Comput. Sci., vol. 167, pp. 101–112, doi: <https://doi.org/10.1016/j.procs.2020.03.187, 2020>
- Wu, J.; Shi, L.; Yang, L.P.; Niu, X.X.; Li, Y.Y.; Cui, X.D.; Tsai, S.B.; Zhang, Y.B. *User Value Identification Based on Improved RFM Model and K-Means++ Algorithm for Complex Data Analysis*. Wirel. Commun. Mob.Com, 9982484, 1–8, 2021 . [https://doi.org/10.1016/S1874-8651\(10\)60001-4](https://doi.org/10.1016/S1874-8651(10)60001-4)