



پژوهش‌های نوین در تصمیم‌گیری

دوره ۱۰، شماره ۴، ویژه نامه مدیریت بازرگانی ۱۴۰۴، صص ۲۶-۵۸

نوع مقاله: پژوهشی

مدل ترکیبی یادگیری ماشین مبتنی بر رأی‌گیری وزنی برای طبقه‌بندی هوشمند ارزش مشتریان بانکی

امیر محمدخانی^۱، احمد جعفرنژاد^{۲*}، آرمان رضاسلطانی^۳

۱. دانشجوی دکتری، گروه مدیریت صنعتی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.
۲. استاد، گروه مدیریت صنعتی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.
۳. دانشجوی دکتری، گروه مدیریت صنعتی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.

تاریخ پذیرش: ۱۴۰۴/۰۳/۳۱

تاریخ دریافت: ۱۴۰۴/۰۱/۲۰

چکیده

در فضای رقابتی صنعت بانکداری، شناسایی و طبقه‌بندی دقیق ارزش مشتریان، نقشی کلیدی در طراحی استراتژی‌های بازاریابی هدفمند، تخصیص بهینه منابع و افزایش سودآوری دارند. این پژوهش، یک مدل ترکیبی پیشرفته مبتنی بر یادگیری ماشین را با استفاده از تکنیک رأی‌گیری وزنی طراحی و پیاده‌سازی می‌کند که هدف آن طبقه‌بندی هوشمند مشتریان بانکی براساس میزان ارزش آنهاست. شش الگوریتم قدرتمند یادگیری ماشین شامل LightGBM، XGBoost، Gradient Boosting، Random Forest، Extra Trees و CatBoost به‌عنوان مدل‌های پایه انتخاب و با دو روش رأی‌گیری سخت و نرم ترکیب شده‌اند. وزن مشارکت هر الگوریتم در فرآیند رأی‌گیری به‌صورت بهینه با الگوریتم Optuna تنظیم گردیده تا دقت و تعادل مدل به حداکثر برسد. همچنین، روش ADASYN برای مقابله با مشکل عدم‌توازن کلاس‌ها در داده‌های واقعی بانکی به کار رفته و مهم‌ترین ویژگی‌های مؤثر در پیش‌بینی با بهره‌گیری از الگوریتم Random Forest شناسایی گردیده‌اند. عملکرد مدل پیشنهادی با استفاده از چهار معیار ارزیابی صحت، دقت، بازخوانی و امتیاز F_1 و در مقایسه با ۱۶ الگوریتم کلاسیک و مدرن یادگیری ماشین تحلیل شده است. نتایج نشان می‌دهد که مدل رأی‌گیری سخت با صحت ۰.۹۴۲۶، دقت ۰.۹۷۵۶ و بازخوانی ۰.۹۱۱۲، و مدل رأی‌گیری نرم با دقت ۰.۹۷۷۱ و امتیاز F_1 معادل ۰.۹۴۲۲، عملکردی برتر از سایر الگوریتم‌ها مانند SVM، KNN و Logistic Regression داشته و تعادلی مؤثر میان معیارهای ارزیابی برقرار کرده‌اند. این مدل ترکیبی، با دقت بالا، مقاومت در برابر داده‌های نامتوازن، و انعطاف‌پذیری در انتخاب ویژگی‌ها، الگویی کاربردی و قابل اتکا برای بانک‌ها و مؤسسات مالی جهت تحلیل ارزش مشتریان فراهم می‌آورد.

کلیدواژه‌ها: ارزش مشتریان بانکی، رأی‌گیری وزنی، یادگیری ماشین، طبقه‌بندی هوشمند



۱- مقدمه و بیان مسئله

در سال‌های اخیر، صنعت بانکداری شاهد تحول قابل‌توجهی بوده است که ناشی از ادغام تکنیک‌های یادگیری ماشین در جنبه‌های مختلف عملیاتی، به‌ویژه در طبقه‌بندی ارزش مشتری بوده است [۱،۲]. این ادغام نه تنها دقت پروفایل مشتری را افزایش می‌دهد، بلکه به بانک‌ها اجازه می‌دهد تا استراتژی‌های بازاریابی هدفمند را اجرا کنند و ارائه خدمات کلی را بهبود بخشند. در محیط رقابتی و پویای صنعت بانکداری، توانایی شناسایی، تحلیل و طبقه‌بندی هوشمند مشتریان براساس ارزش آنها، نقش مهمی در موفقیت و پایداری بانک‌ها ایفا می‌کند. مشتریان با ارزش نه تنها سهم بالایی در سودآوری بانک دارند، بلکه می‌توانند در قالب وفاداری و افزایش تعاملات مالی، مزایای بلندمدتی برای سازمان ایجاد کنند. در این راستا، یادگیری ماشین به عنوان یکی از ابزارهای کلیدی در هوش تجاری و تحلیل داده‌های بزرگ، امکان شناسایی الگوهای رفتاری پنهان در داده‌های تراکنشی مشتریان را فراهم کرده است [۴،۵].

مطالعات مختلفی با هدف بهبود عملکرد مدل‌های طبقه‌بندی از طریق الگوریتم‌های ترکیبی^۱ انجام شده است. به عنوان مثال، گلال^۲ و همکاران (۲۰۲۴) مدل ترکیبی Stacked Ensemble را برای افزایش دقت پیش‌بینی ریزش مشتری به ۸۷/۹ درصد ارائه دادند؛ این مدل با استفاده از بهینه‌سازی ابرپارامترها همراه با رأی‌گیری توسعه داده شد [۶]. در پژوهشی دیگر، چن شووفنگ^۳ و همکاران (۲۰۲۴) نیز پیش‌بینی ریزش مشتریان بانکی در شرایط واقعی را بررسی کردند و نشان دادند که مدل Ensemble چندکلاسه می‌تواند عملکرد پیش‌بینی را به شکل قابل‌توجهی بهبود ببخشد [۷]. همچنین، یائو^۴ و همکاران (۲۰۲۲) با معرفی یک مدل ترکیبی که رأی‌گیری وزنی را با شناسایی داده‌های نویزی ترکیب می‌کند، دقت مدل‌های امتیازدهی اعتباری را افزایش دادند [۸]. کاربرد یادگیری ماشین در صنعت بانکداری به‌طور گسترده مورد مطالعه قرار گرفته است و نقش آن در طبقه‌بندی ارزش مشتریان و تصمیم‌گیری‌های بانکی به خوبی اثبات شده است. پژوهش لی^۵ (۲۰۱۸) نیز طبقه‌بندی مشتریان وام را از طریق الگوریتم‌های داده‌کاوی مانند جنگل تصادفی و ماشین بردار پشتیبان^۱ با استفاده از ویژگی‌های مختلف بررسی کرده است. مطالعات اخیر بر نقش یادگیری ماشین در مدل‌های پیش‌بینی خدمات بانکی

^۱ Hybrid

^۲ Galal

^۳ Chen Shuofeng

^۴ Yao

^۵ Li

^۱ Support vector machines

- SVMs



تاکید و بیان کرده‌اند که این مدل‌ها می‌توانند برای پیش‌بینی واکنش مشتریان نسبت به خدمات بانکی و شخصی‌سازی تعاملات مورد استفاده قرار گیرند [۹]. علاوه بر این، مکانیسم رأی‌گیری وزنی در مدل‌های یادگیری ماشین، برای داده‌های نامتوازن (که در برنامه‌های بانکی رایج هستند) بسیار مؤثر شناخته شده است [۱۰]. به همین دلیل، دیوید^۱ و همکاران (۲۰۱۹) یک چارچوب تصمیم‌گیری مقاوم توسعه داده‌اند که به کمک وزن‌دهی به خروجی‌های طبقه‌بندی‌های مختلف، پیش‌بینی‌های دقیق‌تر و چندبعدی‌تری را فراهم می‌کند [۱۱].

در سال‌های اخیر، صنعت بانکداری با رشد چشمگیر داده‌های تراکشنی و رفتاری مشتریان مواجه بوده است؛ با این حال، بسیاری از بانک‌ها هنوز نتوانسته‌اند از این داده‌ها به صورت مؤثر برای تحلیل ارزش مشتری استفاده کنند. گزارش جهانی دلویت^۲ (۲۰۲۲) نشان می‌دهد که تنها ۳۳ درصد از بانک‌ها از تحلیل‌های پیشرفته مبتنی بر یادگیری ماشین در تصمیم‌گیری‌های مربوط به ارزش مشتری بهره می‌گیرند، در حالی که این رقم در صنایع فناوری به بیش از ۶۰ درصد می‌رسد [۱۲]. از سوی دیگر، مطالعه‌ای توسط مک‌کینزی^۳ (۲۰۲۱) نشان داده است که بانک‌هایی که از مدل‌های داده‌محور برای ارزیابی ارزش مشتری استفاده می‌کنند، به طور میانگین شاهد افزایش ۱۰ تا ۲۰ درصدی در درآمد خالص عملیاتی خود هستند [۱۳]. با وجود این ظرفیت عملیاتی، در حوزه آکادمیک، اغلب مطالعات متمرکز بر پیش‌بینی ریزش مشتری یا خوشه‌بندی وفاداری مشتریان بوده‌اند [۴، ۶] و کمتر به طبقه‌بندی مستقیم ارزش مشتریان با استفاده از داده‌های واقعی بانکی پرداخته‌اند. از منظر فنی نیز، بخش زیادی از پژوهش‌ها از الگوریتم‌های منفرد استفاده کرده‌اند که در مواجهه با داده‌های نامتوازن عملکرد ضعیف‌تری دارند. علاوه بر این، بسیاری از مدل‌های ترکیبی از رأی‌گیری ساده بهره می‌برند و به بهینه‌سازی وزن مدل‌های پایه و تنظیم خودکار هایپرپارامترها بی‌توجه بوده‌اند [۱۵]. همچنین، در ارزیابی عملکرد مدل‌ها نیز تمرکز اغلب بر صحت^۴ بوده، در حالی که معیارهای جامع‌تری نظیر امتیاز^۵ F1 و بازخوانی^۶ که به‌ویژه در مسائل با داده‌های نامتوازن اهمیت دارند، کمتر مورد توجه قرار گرفته‌اند. این کاستی‌ها باعث شده‌اند که در فضای عملیاتی بانک‌ها، مدل‌های طبقه‌بندی ارزش مشتری نتوانند به صورت دقیق، پایدار و قابل اطمینان پیاده‌سازی شوند. در

^۱ Dawood

^۲ Deloitte

^۳ McKinsey

^۴ Accuracy

^۵ F1-score

^۶ Recall



نتیجه، یک شکاف کاربردی در بهره‌گیری از مدل‌های ترکیبی داده‌محور در بانک‌ها و یک شکاف آکادمیک در طراحی مدل‌های بهینه‌سازی شده و مقاوم در برابر داده‌های نامتوازن وجود دارد. پژوهش حاضر با هدف پر کردن این شکاف‌ها، مدلی ترکیبی بر پایه رأی‌گیری وزنی و بهینه‌سازی بیزی (Optuna) ارائه می‌دهد که با استفاده از ADASYN برای متوازن‌سازی کلاس‌ها و انتخاب ویژگی‌های کلیدی، الگویی دقیق و قابل پیاده‌سازی در سیستم‌های تصمیم‌یار بانکی فراهم می‌سازد.

در راستای تحقق این هدف، پژوهش حاضر به دنبال پاسخ به سؤالات زیر است:

۱. مدل ترکیبی پیشنهادی مبتنی بر رأی‌گیری وزنی در مقایسه با الگوریتم‌های یادگیری ماشین منفرد، چه میزان دقت و تعادلی در طبقه‌بندی ارزش مشتریان بانکی ارائه می‌دهد؟
۲. در مقایسه میان دو روش رأی‌گیری نرم و سخت، کدامیک عملکرد مطلوب‌تری از منظر معیارهای ارزیابی چون دقت، بازخوانی، و امتیاز $F1$ ارائه می‌دهد؟
۳. تأثیر استفاده از تکنیک ADASYN در متوازن‌سازی داده‌های نامتوازن و بهبود پیش‌بینی مشتریان با ارزش پایین چگونه است؟
۴. کدام ویژگی‌های رفتاری و تراکنشی مشتریان نقش بیشتری در پیش‌بینی ارزش آن‌ها ایفا می‌کنند؟
۵. مدل پیشنهادی از نظر عملکرد طبقه‌بندی در مقایسه با الگوریتم‌های سنتی مانند Logistic Regression, SVM و KNN چه برتری‌هایی دارد؟

۲- پیشینه پژوهش

به منظور بررسی جایگاه پژوهش حاضر در زمینه طبقه‌بندی مشتریان بانکی با استفاده از مدل‌های ترکیبی یادگیری ماشین، جدول ۱ مروری نظام‌مند بر مهم‌ترین مطالعات داخلی و بین‌المللی انجام‌شده در سال‌های اخیر ارائه می‌دهد. این جدول شامل اطلاعاتی درباره نام نویسندگان، عنوان پژوهش، اهداف اصلی، نتایج به‌دست آمده و الگوریتم یا مدل ترکیبی مؤثر در هر مطالعه است. با مرور این مطالعات، نه تنها روند پیشرفت علمی در این حوزه روشن، بلکه شکاف موجود در تحقیقات پیشین نیز شناسایی می‌شود که زمینه‌ساز طراحی مدل ترکیبی پیشنهادی در این تحقیق بوده‌اند.



جدول ۱: پیشینه پژوهش

منبع	بهترین الگوریتم	نتیجه گیری	هدف	عنوان پژوهش	نویسندگان
[۱۶]	ماشین بردار پشتیبان با تنظیم بهینه توسط الگوریتم ژنتیک	مدل ترکیبی توانست با دقت ۹۹/۹۷ درصد مشتریان را به درستی طبقه‌بندی کند؛ نشان‌دهنده کارایی بالای مدل است.	پیش‌بینی عملکرد مشتریان جدید بر اساس رفتار مشتریان قبلی با استفاده از SVM و الگوریتم ژنتیک	ارائه یک مدل ترکیبی مبتنی بر یادگیری ماشینی برای طبقه‌بندی مشتریان مشترک بانک و بیمه	امیرحسین‌خانی و همکاران (۱۴۰۳)
[۱۷]	مدل مارکوف سوئیچینگ + LRFM	استفاده از مدل‌های بیزین و مارکوف سوئیچینگ در کنار مدل LRFM توانست دسته‌بندی مناسبی از مشتریان ارائه دهد و شاخص‌هایی مانند مانده حساب بلنمدت، تعداد تراکنش و وفاداری را شناسایی کند.	شناسایی عوامل مؤثر بر ارزش طول عمر مشتری و خوشه‌بندی مشتریان بانک تجارت با مدل ترکیبی	توسعه مدل ارتباط با مشتری مبتنی بر مزیت رقابتی با استفاده از مدل مارکوف و دسته‌بندی LRFM	حسینی و همکاران (۱۴۰۳)
[۱۸]	PrefixSpan + Spark	الگوریتم کاوش دنباله‌ای PrefixSpan با حداقل پشتیبانی ۲۰ درصد و پردازش توزیع شده بر بستر Spark، توانست الگوهای معنی‌داری از مشتریان وفادار، در حال رشد و ریزشی استخراج کند.	تحلیل تغییرات رفتار مشتریان بانکی در طول زمان با رویکرد کاوش الگوها	مدل‌سازی پویا در سطوح مختلف ارزش مشتری با استفاده از کاوش الگوهای دنباله‌ای داده‌های کلان	نجفی و آخوندزاده نوبابی (۱۴۰۳)
[۱۹]	درخت تصمیم C۵/۰	الگوریتم درخت تصمیم C۵/۰ دقت بالاتری نسبت به شبکه بیزی داشته و در پیش‌بینی مشتریان وفادار عملکرد بهتری دارد.	پیش‌بینی رفتار ریزش مشتریان با استفاده از ترکیب الگوریتم‌های یادگیری ماشین	تحلیل ریزش مشتریان بر اساس رویکرد داده‌کاوی؛ الگوریتم ترکیبی شامل درخت تصمیم و شبکه بیزی	آقاخانی و حسینی (۱۴۰۲)
[۲۰]	شبکه عصبی بازگشتی با ورودی برون‌زاد (NARX)	ترکیب الگوریتم خوشه‌بندی سری زمانی DTW و شبکه عصبی NARX باعث بهبود قابل توجه دقت پیش‌بینی تقاضا شد.	کاهش عدم قطعیت در خرده‌فروشی همه‌کاناله از طریق تحلیل رفتار خرید مشتریان و پیش‌بینی دقیق‌تر تقاضا	ارائه یک رویکرد یکپارچه برای پیش‌بینی تقاضای همه‌کاناله با استفاده از خوشه‌بندی سری زمانی و شبکه عصبی	سلطانی و همکاران (۱۴۰۲)



نویسندگان	عنوان پژوهش	هدف	نتیجه گیری	بهترین الگوریتم	منبع
زو ^۱ (۲۰۲۴)	پیش‌بینی ریزش مشتریان بانکی با روش‌های یادگیری ماشین	تحلیل و مقایسه الگوریتم‌های مختلف یادگیری ماشین برای پیش‌بینی ریزش مشتریان و تأکید بر نقش حیاتی آن در مدیریت استراتژیک بانک‌هاست.	این پژوهش بر اهمیت پیش‌بینی دقیق ریزش مشتری تأکید دارد تا از زیان‌های درآمدی جلوگیری شود و نشان می‌دهد که اتخاذ استراتژی‌های مؤثر یادگیری ماشین چقدر اهمیت دارد.	چندین روش یادگیری ماشین مورد بررسی قرار گرفتند و نتایج نشان دادند که عملکرد آنها متغیر بوده است.	[۲۱]
شوونگ و همکاران (۲۰۲۴)	یک رویکرد یادگیری جمعی چندکلاسه برای پیش‌بینی ریزش مشتریان در بانک‌های تجاری	معرفی راهکارهای پیش‌بینی چندکلاسه با استفاده از روش‌های جمعی برای پیش‌بینی مؤثر ریزش مشتری است.	این رویکرد بر کاربردپذیری روش‌های جمعی در بهبود دقت پیش‌بینی ریزش مشتری تأکید دارد و مدل‌ها را به گونه‌ای تنظیم می‌کند که برای طبقات خاص مشتریان بهینه باشند.	استفاده از استراتژی‌های جمعی، پیش‌بینی ریزش مشتری را به طور قابل توجهی ارتقاء داده است.	[۷]
هی و کریس ^۲ (۲۰۲۴)	یک الگوریتم طبقه‌بندی نوآورانه برای پیش‌بینی ریزش مشتری بر پایه مدل ترکیبی Ensemble-Fusion	توسعه یک مدل ترکیبی Ensemble-Fusion با ترکیب چند الگوریتم یادگیری ماشین برای پیش‌بینی ریزش مشتری	مدل Ensemble-Fusion دقت، AUC و امتیاز F1 بالاتری نسبت به ۱۷ الگوریتم مرجع به دست آورد.	ترکیب الگوریتم‌های مختلف در قالب مدل ترکیبی Ensemble-Fusion	[۲۲]
گالال و همکاران (۲۰۲۴)	افزایش پیش‌بینی ریزش مشتری در بانکداری دیجیتال با استفاده از فرآیند آموزش ترکیبی	بهبود دقت پیش‌بینی ریزش با استفاده از یادگیری جمعی	انباشته شدن با گروه رای‌گیری به طور قابل توجهی ROC_AUC را به ۸۷/۹ درصد بهبود می‌بخشد.	جمعی انباشته + یادگیرندگان پایه بهینه شده	[۶]

^۱ Zhu

^۲ He and Chris



منبع	بهترین الگوریتم	نتیجه گیری	هدف	عنوان پژوهش	نویسندگان
[۲۳]	Stacking Ensemble + KNN Random Forest AdaBoost Gradient Boosting	با استفاده از مدل ترکیبی انباشته‌شده (Stacked Ensemble) با رأی‌گیری وزنی، به دقت ۸۸/۹ درصد دست یافتیم.	پیش‌بینی وفاداری مشتریان جوان برای حمایت از استراتژی بانکداری دیجیتال	افزایش کارایی مهندسی یادگیری ماشین برای پیش‌بینی وفاداری جوانان در بانکداری دیجیتال	گالال و همکاران (۲۰۲۴ب)
[۲۴]	جنگل تصادفی، ماشین بردار پشتیبان	الگوریتم‌های جنگل تصادفی (Random Forest) و ماشین بردار پشتیبان (SVM) بهترین عملکرد را در طبقه‌بندی مشتریان براساس ارزش آنها ارائه دادند.	شناسایی و بخش‌بندی مشتریان با ارزش بالا با استفاده از تکنیک‌های یادگیری ماشین	ارزیابی الگوریتم‌های یادگیری ماشین در پیش‌بینی بهترین مشتریان بانک	محمد و همکاران (۲۰۲۳)
[۸]	رأی‌گیری وزنی + استکینگ + فیلتر کردن نویز	رأی‌گیری وزنی همراه با مدل ترکیبی (Stacking) باعث افزایش دقت پیش‌بینی شد.	بهبود امتیازدهی اعتباری (Credit Scoring) از طریق حذف داده‌های نویزی و استفاده از رأی‌گیری ترکیبی	مدل نوآورانه هیبریدی امتیازدهی اعتباری با تشخیص نویز مبتنی بر استکینگ و تخصیص وزن	یائو و همکاران (۲۰۲۲)
[۲۵]	رأی‌گیری تقویت‌شده + الگوریتم ژنتیک	رأی‌گیری تقویت‌شده با استفاده از ویژگی‌های انتخاب‌شده توسط الگوریتم ژنتیک عملکردی قدرتمند و مقاوم نشان داد.	بهبود امتیازدهی اعتباری از طریق ترکیب انتخاب ویژگی و رأی‌گیری	مدل ترکیبی با انتخاب ویژگی و رأی‌گیری تقویت‌شده	یائو و همکاران (۲۰۲۲)
[۲۶]	Stacking + Voting + Bagging	مدل تقویت‌شده با رأی‌گیری عملکرد بهتری نسبت به مدل‌های کلاسیک Ensemble داشت.	افزایش دقت پیش‌بینی با کاهش نویز و متعادل‌سازی داده‌ها	شناسایی داده‌های پرت مبتنی بر رأی‌گیری برای امتیازدهی اعتباری	ژانگ ^۱ و همکاران (۲۰۲۱)

^۱ Zhang



مطالعات پیشین داخلی و خارجی نشان‌دهنده رشد فزاینده استفاده از الگوریتم‌های یادگیری ماشین در حوزه تحلیل و طبقه‌بندی مشتریان بانکی هستند. با این حال، بررسی انتقادی این پژوهش‌ها حاکی از آن است که بیشتر آنها یا بر پیش‌بینی ریزش مشتری تمرکز داشته‌اند [۷،۲۳]، یا به خوشه‌بندی رفتاری و وفاداری مشتریان پرداخته‌اند [۱۷،۱۸]. تعداد معدودی از پژوهش‌ها به مسئله اصلی این تحقیق، یعنی طبقه‌بندی هوشمند ارزش مشتریان بانکی براساس داده‌های تراکنشی واقعی با رویکرد ترکیبی مبتنی بر رأی‌گیری وزنی، به صورت مستقیم پرداخته‌اند. از منظر تکنیکی نیز بیشتر تحقیقات قبلی به یکی از محدودیت‌های زیر دچار بوده‌اند: عدم مدیریت مناسب داده‌های نامتوازن^۱، بی‌توجهی به انتخاب ویژگی‌های بهینه، یا استفاده از مدل‌های ترکیبی بدون تنظیم وزن رأی‌گیری و بهینه‌سازی خودکارهای پیرامون آنها. به عنوان مثال، برخی مطالعات صرفاً از رأی‌گیری ساده یا مدل‌های stacking استفاده کرده‌اند، اما رویکرد وزن‌دهی دقیق مدل‌های پایه با استفاده از الگوریتم‌های بهینه‌سازی مانند Optuna نادیده گرفته شده است [۲۵،۲۶]. همچنین، در بسیاری از پژوهش‌ها، ارزیابی مدل‌ها صرفاً براساس معیار «صحت» صورت گرفته و معیارهای جامع‌تری نظیر امتیاز F_1 ، دقت^۲ و بازخوانی بررسی نشده‌اند.

در این میان، سهم اصلی پژوهش حاضر طراحی و ارزیابی یک چارچوب کامل و دقیق برای طبقه‌بندی ارزش مشتریان بانکی است که سه نوآوری کلیدی دارد:

۱. استفاده همزمان از ۶ الگوریتم قدرتمند یادگیری ماشین به‌عنوان مدل‌های پایه در

ترکیب؛

۲. تنظیم وزن‌های رأی‌گیری سخت و نرم براساس بهینه‌سازی بیزی توسط Optuna؛ و

۳. مدیریت دقیق داده‌های نامتوازن با استفاده از تکنیک ADASYN و انتخاب ویژگی هدفمند

با الگوریتم Random Forest.

در مجموع، این تحقیق با پاسخ به شکاف‌های فنی و کاربردی موجود، مدلی ارائه می‌دهد که هم در عملکرد الگوریتمی و هم در کارایی عملیاتی برای بانک‌ها قابل‌اتکا و توسعه‌پذیر است. همچنین، با مقایسه جامع با ۱۶ الگوریتم یادگیری ماشین رایج، نشان داده است که مدل

^۱ class imbalance

^۲ Precision



پیشنهادی از منظر ارزیابی‌های چندگانه برتری محسوسی دارد، که در مطالعات پیشین کمتر به صورت کمی و تطبیقی گزارش شده است.

۳- روش‌شناسی پژوهش

پژوهش حاضر از منظر فلسفه پژوهش، مبتنی بر رویکرد اثبات‌گرایی است؛ چراکه با استفاده از داده‌های عددی و تحلیل‌های آماری به دنبال کشف روابط قابل تعمیم و تکرارپذیر میان متغیرهاست. از حیث رویکرد، این تحقیق از نوع قیاسی بوده و بر پایه نظریه‌ها و پیشینه مطالعاتی موجود، فرضیه‌ها و ساختار مدل پیشنهادی خود را توسعه داده و آن‌ها را با داده‌های واقعی بانکی آزموده است. راهبرد اصلی به‌کاررفته در این پژوهش، مدل‌سازی کمی مبتنی بر یادگیری ماشین است که از طریق اجرای مدل‌های ترکیبی و مقایسه نتایج آن‌ها با مدل‌های منفرد انجام شده است. روش تحقیق از منظر انتخاب، در دسته تک‌روشی کمی قرار می‌گیرد؛ به این معنا که تمام مراحل پژوهش، از جمع‌آوری داده تا تحلیل نتایج، بر مبنای داده‌های عددی و روش‌های آماری و الگوریتمی انجام شده است. افق زمانی پژوهش مقطعی است، زیرا داده‌های مربوط به مشتریان بانکی تنها در یک بازه زمانی مشخص (یک‌ساله) مورد بررسی قرار گرفته‌اند. نهایتاً، از نظر نحوه گردآوری داده، تحقیق حاضر به داده‌های ثانویه متکی است؛ به‌گونه‌ای که داده‌های خام مربوط به تراکنش‌های مشتریان، از پایگاه اطلاعاتی بانک انتخاب‌شده استخراج شده و پس از آماده‌سازی، برای مدل‌سازی مورد استفاده قرار گرفته‌اند. جامعه آماری پژوهش شامل ۲۰۰۰ مشتری بانک است که اطلاعات حساب بانکی آنها در بازه‌های یک‌ساله گردآوری شده است. در این مجموعه، ۱۳۹۷ نمونه مربوط به مشتریان بارز (کلاس ۱) و ۶۰۳ نمونه مربوط به مشتریان بی‌ارزش (کلاس صفر) ثبت شده که نشان‌دهنده عدم توازن معنادار بین کلاس‌ها می‌باشد. برای هر مشتری، ۱۴ ویژگی مربوط به تراکنش‌ها و رفتار مالی موجود بوده که خلاصه آنها در جدول ۲ آمده است. در گام نخست، برای حذف ویژگی‌های تکراری و مرتبط، از ماتریس همبستگی استفاده شد و سپس با کمک الگوریتم Random Forest بهینه‌شده توسط Optuna، میزان اهمیت ویژگی‌ها محاسبه شد [۱۵]. در نتیجه این فرآیند، ۸ ویژگی کلیدی، به‌عنوان ورودی نهایی مدل انتخاب گردید. پس از آن، به منظور افزایش دقت مدل و هم‌ترازی مقادیر عددی، ویژگی‌ها با StandardScaler نرمال‌سازی شدند. با توجه به نامتوازن بودن کلاس‌ها، از روش نمونه‌سازی تطبیقی ADASYN برای ایجاد



تعادل استفاده شد. ADASYN با تولید نمونه‌های مصنوعی برای کلاس اقلیت (مشتریان بی‌ارزش) به توزیع متوازن‌تری در داده‌ها منجر شد و عملکرد مدل در شناسایی این گروه را بهبود بخشید [۲۷]. در ادامه، شش الگوریتم قدرتمند شامل Gradient Boosting، Random Forest، XGBoost، LightGBM، CatBoost و Extra Trees به‌عنوان مدل‌های پایه مورد استفاده قرار گرفتند. هایپارامترهای این مدل‌ها به‌صورت مجزا با Optuna بهینه‌سازی شدند و سپس ترکیب آنها با استفاده از دو استراتژی رأی‌گیری سخت^۱ و رأی‌گیری نرم^۲ انجام شد. وزن مشارکت هر مدل در رأی‌گیری نیز به‌طور جداگانه و دقیق تنظیم شد تا مدل‌های مؤثرتر نقش پررنگ‌تری در خروجی داشته باشند. برای ارزیابی دقیق عملکرد مدل ترکیبی، از روش اعتبارسنجی متقاطع^۳ پنج‌تایی و ۴ شاخص ارزیابی شامل صحت، دقت، بازخوانی امتیاز F^۱ استفاده گردید. در پایان، عملکرد مدل ترکیبی با ۱۶ الگوریتم پرکاربرد یادگیری ماشین نیز مورد مقایسه قرار گرفت. به‌منظور درک بهتر ساختار اجرای تحقیق و چگونگی پاسخ‌دهی به هر یک از سؤالات پژوهش، در شکل ۱ مراحل مختلف پژوهش از ابتدا تا پایان به‌صورت گام‌به‌گام ترسیم شده‌اند. در این نمودار، هر مرحله از تحقیق با ابزارهای مورد استفاده مشخص شده و همچنین بیان شده است که هر مرحله به کدام یک از سؤالات تحقیق پاسخ می‌دهد. این رویکرد کمک می‌کند تا پیوند منطقی میان اجزای تحقیق و اهداف اصلی پژوهش به‌صورت شفاف و منسجم تبیین شود.

جدول ۲: اطلاعات مربوط به ویژگی‌های مجموعه داده

نام ویژگی	نوع ویژگی	توضیحات
آخرین تاخر	عددی	آخرین تعداد روزهایی که مشتری تراکنشی نداشته است
حداکثر تاخر	عددی	بیشترین تعداد روزهایی که مشتری تراکنشی نداشته است
کمترین تاخر	عددی	کمترین تعداد روزهایی که مشتری تراکنشی نداشته است
تعداد دفعات مراجعه	عددی	تعداد دفعات مراجعه به بانک توسط مشتری
جمع کل واریزی‌ها	عددی	جمع کل مبلغ واریزی‌های مشتری
تعداد کل واریزی‌ها	عددی	تعداد کل واریزی‌های مشتری
جمع کل برداشت‌ها	عددی	جمع کل مبلغ برداشت‌های مشتری
تعداد کل برداشت‌ها	عددی	تعداد کل برداشت‌های مشتری
کمترین مانده	عددی	کمترین مانده حساب مشتری

^۱ Hard Voting

^۲ Soft Voting

^۳ Cross-Validation



نام ویژگی	نوع ویژگی	توضیحات
بیشترین مانده	عددی	بیشترین مانده حساب مشتری
تعداد کل خدمات	عددی	تعداد کل خدماتی که مشتری استفاده کرده است
کل تراکنش‌های غیرحضوری	عددی	کل تراکنش‌های غیرحضوری مشتری
آخرین مانده	عددی	آخرین مانده حساب مشتری
ارزش مشتری	باینری	ارزش مشتری (۱ با ارزش و صفر بی ارزش)



شکل ۱. نمودار مراحل اجرای پژوهش و ابزارهای مورد استفاده برای پاسخ به سؤالات تحقیق




۳-۱- پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها یکی از مراحل کلیدی و فنی در آماده‌سازی داده‌ها برای تحلیل و مدل‌سازی است که هدف آن، بهبود کیفیت و ساختار داده‌ها جهت استفاده در الگوریتم‌های یادگیری ماشین می‌باشد. این فرآیند شامل اصلاح، حذف یا جایگزینی داده‌های ناقص، نامعتبر، نامرتب، یا تکراری و در صورت لزوم، تبدیل داده‌های متنی به مقادیر عددی و بازطراحی ویژگی‌هاست. در این پژوهش، بررسی داده‌ها نشان داد که هیچ داده‌ای حذف نشده و همچنین مقداری داده تکراری در مجموعه وجود نداشته است. داده‌های پرت نیز بسیار اندک و در مقایسه با حجم کل داده‌ها قابل اغماض بوده‌اند. یکی دیگر از گام‌های رایج در مرحله پیش‌پردازش، مقیاس‌سازی ویژگی‌ها است. مقیاس‌سازی به منظور هم‌ترازسازی محدوده مقادیر متغیرهای ورودی انجام می‌شود تا عملکرد مدل‌ها بهینه‌تر گردد. در این تحقیق، ویژگی‌های عددی با استفاده از روش StandardScaler مقیاس‌بندی شدند. StandardScaler از کتابخانه scikit-learn در پایتون بهره می‌برد و داده‌ها را به گونه‌ای تبدیل می‌کند که میانگین هر ویژگی برابر صفر و انحراف معیار آن برابر یک باشد [۲۸]. این استانداردسازی موجب می‌شود توزیع مقادیر ویژگی‌ها به شکل متعادلی در فضای ویژگی قرار گیرد و الگوریتم‌ها عملکرد دقیق‌تری داشته باشند.


۳-۲- انتخاب مهم‌ترین ویژگی‌ها

به منظور شناسایی ویژگی‌های کلیدی مؤثر در پیش‌بینی، یک فرآیند مرحله‌ای و هدفمند برای انتخاب ویژگی‌ها اجرا شد. در گام نخست، جهت بررسی میزان وابستگی بین متغیرها، از ماتریس همبستگی استفاده گردید. هدف اصلی این مرحله، تشخیص ویژگی‌هایی بود که همبستگی بسیار بالا با یکدیگر دارند و ممکن است محتوای اطلاعاتی مشابهی را در اختیار مدل قرار دهند. برای این منظور، از ضریب همبستگی پیرسون جهت محاسبه روابط بین ویژگی‌ها بهره گرفته شد [۲۹]. آن دسته از ویژگی‌هایی که دارای همبستگی بالاتر از ۸۰ درصد بودند، به عنوان ویژگی‌های تکراری یا دارای هم‌خطی بالقوه در نظر گرفته شدند. شکل ۲ نمایی از نقشه گرمایی همبستگی را ارائه می‌دهد که در آن شدت ارتباط بین ویژگی‌ها به وضوح قابل مشاهده است.



شکل ۲. نقشه گرمایی همبستگی ویژگی‌های مختلف مشتریان بانکی

برای انتخاب ویژگی‌های نهایی، از روش اهمیت ویژگی‌ها مبتنی بر الگوریتم Random Forest استفاده شد [۳۰]. پارامترهای این الگوریتم با تکنیک Optuna بهینه‌سازی شدند تا دقت مدل و فرآیند انتخاب ویژگی بهبود یابد. این الگوریتم مقدار اهمیت هر ویژگی را محاسبه می‌کند تا مشخص شود هر متغیر تا چه حد در کاهش خطای مدل و بهبود عملکرد پیش‌بینی نقش دارد. بر این اساس، ویژگی‌هایی که اهمیت بیشتری داشتند در مدل حفظ شدند، درحالی‌که ویژگی‌های دارای همبستگی بالا ولی اهمیت کمتر حذف شدند. نمودار شکل ۳ اهمیت نسبی ویژگی‌ها را در پیش‌بینی ارزش مشتریان بانک نشان می‌دهد؛ این مقادیر براساس خروجی الگوریتم Random Forest بهینه‌سازی شده محاسبه شده‌اند.



شکل ۳. اهمیت ویژگی‌ها براساس الگوریتم جنگل تصادفی

این فرآیند منجر به انتخاب ۸ متغیر مهم شد که به عنوان موثرترین متغیرها انتخاب شدند که عبارتند از: آخرین تأخر، حداکثر تأخر، کمترین تأخر، تعداد دفعات مراجعه، جمع کل واریزی‌ها، تعداد کل برداشتها، تعداد کل خدمات، و کل تراکتهای غیرحضوری. مدل نهایی با استفاده از یک رویکرد ترکیبی داده شده آموزش داده شد، که در آن، با استفاده از یک داده مفید و غیرتکراری، چنین ویژگی مهمی را با استفاده از تحلیل همبستگی و ارزیابی اهمیت ویژگی برای انجام ترکیب می‌کند. این انتخاب هوشمند منجر به یک مدل کوچکتر با سطح بالاتری از دقت پیش‌بینی شد و از بروز هرگونه مشکل ناشی از هم‌خطی بودن ویژگی‌ها جلوگیری کرد.

۳-۳- مدیریت داده‌های نامتعادل

عدم توازن در داده‌ها یکی از چالش‌های اصلی این پژوهش بود؛ به طوری که نمونه‌های مربوط به مشتریان بی‌ارزش (کلاس ۰) به مراتب کمتر از مشتریان باارزش (کلاس ۱) بودند. این عدم تعادل باعث کاهش دقت مدل در شناسایی کلاس اقلیت می‌شود. برای رفع این مشکل، از روش



نمونه‌گیری مصنوعی تطبیقی (ADASYN) استفاده شد که با تولید داده‌های مصنوعی برای کلاس اقلیت، داده‌ها را به‌طور هوشمند متوازن می‌کند. برخلاف SMOTE، این روش بر نمونه‌های سخت‌تر تمرکز دارد؛ یعنی مواردی که نزدیک به مرز تصمیم یا دارای تراکم پایین هستند، تا مدل عملکرد بهتری در شناسایی این نمونه‌ها داشته باشد [۳۱]. در ادامه، مراحل اجرای ADASYN به‌صورت تفصیلی ارائه شده است.

۱. محاسبه نسبت عدم تعادل کلاس‌ها

در گام نخست، تعداد نمونه‌های مربوط به کلاس اکثریت (N_{maj}) و کلاس اقلیت (N_{min}) محاسبه می‌گردد. پس از آن، برای اندازه‌گیری شدت عدم تعادل در داده‌ها، نسبت عدم تعادل (d) میان این دو کلاس به‌صورت زیر تعریف می‌شود.

$$d = \frac{N_{maj} - N_{min}}{N_{min}}$$

۲. محاسبه سختی نمونه‌های کلاس اقلیت

برای هر نمونه x_i متعلق به کلاس اقلیت، تعداد همسایگان آن از کلاس اکثریت در یک شعاع مشخص (که معمولاً با استفاده از الگوریتم k -نزدیک‌ترین همسایه‌ها) تعیین می‌شود. در ادامه، میزان دشواری یا سختی طبقه‌بندی نمونه r_i براساس نسبت همسایگان اکثریت به‌صورت زیر محاسبه می‌گردد.

$$r_i = \frac{\text{تعداد همسایگان کلاس اکثریت برای } x_i}{k}$$

۳. نرمال‌سازی وزن‌ها

وزن r_i برای هر نمونه از کلاس اقلیت نرمال‌سازی می‌شود تا مجموع وزن‌ها برابر ۱ شود. G_i وزن نرمال‌شده نمونه x_i است. این کار به‌صورت زیر انجام می‌شود:

$$G_i = \frac{r_i}{\sum_{j=1}^{N_{min}} r_j}$$

۴. تولید نمونه‌های مصنوعی

نمونه‌های مصنوعی با استفاده از ترکیب خطی نقاط اصلی و نزدیک‌ترین همسایگان آن تولید می‌شوند. برای هر نمونه x_i نمونه مصنوعی x_{new} با فرمول زیر ایجاد می‌شود که در آن x_{mn} یکی



از نزدیک‌ترین همسایگان x_i و λ یک مقدار تصادفی بین ۰ و ۱ که تنوع نمونه‌های مصنوعی را تضمین می‌کند.

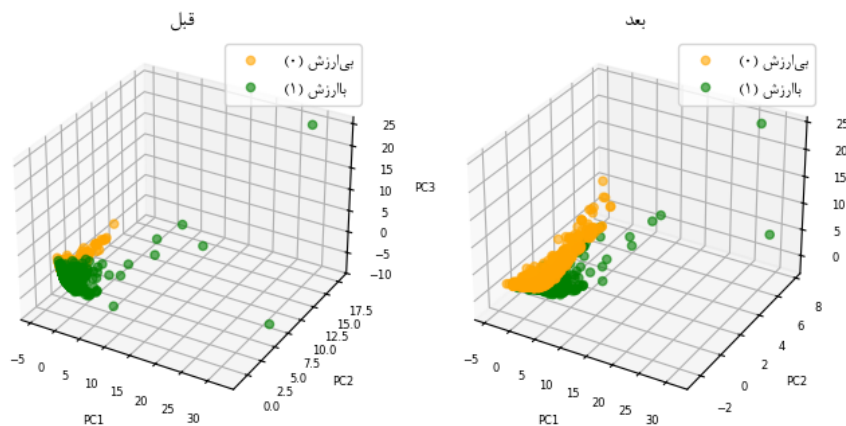
$$x_{new} = x_i + \lambda(x_{nm} - x_i)$$

۵. تعداد نمونه‌های مصنوعی تولید شده

مقدار کلی نمونه‌های مصنوعی که باید تولید شوند، با نماد G نمایش داده می‌شود و طبق رابطه‌ای مشخص محاسبه می‌گردد. در این رابطه، پارامتر β تعیین‌کننده میزان توازن نهایی بین کلاس‌هاست که معمولاً مقدار آن در بازه‌ای بین ۰ تا ۱ انتخاب می‌شود.

$$G = (N_{maj} - N_{min}) \times \beta$$

در حالت اولیه، مجموعه داده شامل ۱۳۹۷ مشتری با ارزش (کلاس ۱) و ۶۰۳ مشتری بی‌ارزش (کلاس ۰) بود که نشان‌دهنده عدم تعادل قابل توجه در برچسب‌هاست. با اعمال روش ADASYN، تعداد نمونه‌های کلاس ۰ به ۱۳۵۵ افزایش یافت. شکل ۴ نمای سه‌بعدی داده‌ها با استفاده از PCA را قبل و بعد از متوازن‌سازی نشان می‌دهد. در تصویر سمت چپ، تراکم بالای کلاس ۱ و پراکندگی محدود کلاس ۰ مشهود است. در حالی که پس از ADASYN (تصویر سمت راست)، توزیع نمونه‌ها متعادل‌تر شده و مرز بین کلاس‌ها شفاف‌تر است. این امر به آموزش بهتر مدل‌های طبقه‌بندی کمک می‌کند.



شکل ۴. نمایش سه‌بعدی داده‌ها با PCA قبل و بعد از متوازن‌سازی با ADASYN




در این پژوهش، انتخاب روش‌ها و ابزارها بر مبنای نیازهای مسئله و شواهد تجربی صورت گرفته است. برای حل مشکل عدم توازن داده‌ها، از روش ADASYN استفاده شد که با تولید نمونه‌های مصنوعی تطبیقی، عملکرد بهتری نسبت به روش‌هایی مانند SMOTE در شناسایی کلاس‌های اقلیت دارد. در مرحله انتخاب ویژگی‌ها، الگوریتم Random Forest به کار گرفته شد که با ارزیابی اهمیت متغیرها، ویژگی‌های کلیدی مؤثر بر طبقه‌بندی را شناسایی می‌کند. برای بهبود دقت مدل‌ها و افزایش پایداری، از شش الگوریتم یادگیری ماشین قدرتمند شامل Random Forest, XGBoost, LightGBM, CatBoost, Gradient Boosting, و Extra Trees بهره گرفته شد که در مسائل بانکی به دلیل مقاومت در برابر نویز و دقت بالا عملکرد اثبات‌شده‌ای دارند. ترکیب این مدل‌ها با دو روش رأی‌گیری سخت و نرم انجام شد تا نقاط قوت آن‌ها جمع شود. به منظور تنظیم بهینه وزن هر مدل و هایپرپارامترها، از الگوریتم Optuna استفاده گردید که با بهینه‌سازی بیزی، دقت نهایی مدل را بهبود می‌بخشد. همچنین برای استانداردسازی ویژگی‌ها، ابزار StandardScaler انتخاب شد تا هم‌ترازی مقیاس متغیرها حفظ شود و عملکرد الگوریتم‌ها بهینه گردد. بنابراین، ابزارها و روش‌های انتخاب‌شده نه تنها با طبیعت داده‌ها و هدف تحقیق همخوانی دارند، بلکه بر پایه مطالعات معتبر و تجربیات موفق پیشین در حوزه تحلیل داده‌های بانکی انتخاب شده‌اند.

۳-۴- مدل‌سازی با روش یادگیری جمعی مبتنی بر رأی‌گیری

در این مطالعه از رویکرد یادگیری جمعی مبتنی بر رأی وزنی، با هدف ساخت یک مدل ترکیبی بسیار دقیق برای پیش‌بینی ارزش مشتریان بانک و کاهش خطاهای تصمیم‌گیری استفاده شده است. برای این مدل ترکیبی از شش الگوریتم یادگیری ماشین بسیار قدرتمند مانند Random Forest, Gradient Boosting, XGBoost, LightGBM, CatBoost, و Extra Trees به عنوان مدل‌های پایه استفاده شد. الگوریتم‌های انتخاب‌شده به دلیل برتری در مسائل طبقه‌بندی، توانایی در شناسایی روابط پیچیده در داده‌ها و همچنین مقاومت نسبی در برابر نویز مورد استفاده قرار گرفته‌اند. این ویژگی‌ها آن‌ها را به گزینه‌هایی مناسب برای استفاده در مدل‌های ترکیبی و داده‌های با ساختار پیچیده تبدیل می‌کند. الگوریتم جنگل تصادفی براساس مجموعه‌ای از درختان تصمیم است که با تولید تصادفی درختان مختلف و ترکیب نتایج از این درختان مختلف، واریانس را کاهش داده و پایداری پیش‌بینی زیر را افزایش می‌دهد. Gradient Boosting یک



روش افزایشی است، مدل‌های ضعیف را به صورت متوالی آموزش می‌دهد و با مدل بعدی خود خطاها را تصحیح می‌کند. Gradient Boosting الگوریتمی است که ایده تقویت را پیاده‌سازی می‌کند و با استفاده از تکنیک‌های هرس، موازی‌سازی و منظم‌سازی بهینه‌سازی شده است تا دقت بهتر و زمان تمرین سریع‌تری نسبت به الگوریتم تقویت گرادیان استاندارد داشته باشد. ساخت درخت‌های تصمیم‌گیری سریع‌تر و کم‌مصرف‌تر، در LightGBM به ترتیب Leaf-wise (به جای Level-wise) است. برای داده‌های دسته‌ای، Catboost الگوریتمی است که به طور ویژه برای کار با آن طراحی شده است و نیازی به پیش‌پردازش مانند One Hot Encoding ندارد. علاوه بر این، الگوریتم Extra Trees یک نسخه جایگزین سریع و تصادفی از Random Forest است که دوباره نتایج خوبی در مورد داده‌های پرت و پر نویز دارد. استفاده از مجموعه‌ای از درختان تصمیم تصادفی، نقش مهمی در کاهش واریانس و بهبود پایداری نتایج به مدل جنگل تصادفی داده است. این به لطف ساختار افزایشی الگوریتم‌های خانواده تقویت‌کننده مانند Gradient Boost، XG Boost، Cat Boost و LightGBM، قدرت پیش‌بینی مدل را افزایش داد، که همچنین اجازه می‌دهد تا خطاهای آنها را بهینه کنید. علاوه بر این، Extra Trees به عنوان یک روش سریع مقاوم در برابر نویزهای پرت و نویز به مجموعه مدل اضافه شد. گردش کار طبقه‌بندی کننده مبتنی بر رأی‌گیری در شکل ۵ نشان داده شده است.



شکل ۵. جریان کاری طبقه‌بند مبتنی بر رأی‌گیری

برای دستیابی به بهترین عملکرد هر یک از الگوریتم‌ها، بهینه‌سازی‌های پارامترها توسط الگوریتم Optuna صورت گرفت. این الگوریتم، یک چارچوب قدرتمند و منعطف برای بهینه‌سازی



خودکار هایپرپارامترهای مدل‌های یادگیری ماشین است که بر مبنای رویکرد جستجوی مبتنی بر نمونه‌گیری و بهینه‌سازی بیزی عمل می‌کند [۳۲]. این الگوریتم به صورت هوشمند فضای جستجوی هایپرپارامترها را کاوش کرده و با توجه به نتایج به دست آمده از ارزیابی مدل، به تدریج بهترین ترکیب پارامترها را شناسایی می‌کند. به عبارت دیگر، Optuna ابتدا با مقادیر تصادفی هایپرپارامترها شروع کرده و سپس براساس اطلاعات کسب شده از آزمون‌های قبلی، نقاط امیدوارکننده‌تری را برای ارزیابی انتخاب می‌کند. این روند تا یافتن بهترین تنظیمات هایپرپارامترها که منجر به بیشترین دقت و کمترین خطا شود ادامه پیدا می‌کند. استفاده از Optuna در این پژوهش باعث شد تا هر الگوریتم به دقیق‌ترین حالت ممکن تنظیم شود و توانایی پیش‌بینی مدل‌های منفرد و در نتیجه مدل نهایی به طور چشمگیری افزایش یابد. پس از این مرحله، دو نوع رأی‌گیری وزنی شامل رأی‌گیری نرم و رأی‌گیری سخت پیاده‌سازی شدند. در رأی‌گیری سخت، هر مدل یک کلاس مشخص را به عنوان خروجی پیش‌بینی می‌کند و نتیجه نهایی براساس بیشترین رأی مشخص می‌شود [۳۳]. در رأی‌گیری نرم، احتمال پیش‌بینی هر کلاس توسط مدل‌های پایه به صورت وزنی ترکیب شده و میانگین موزون این احتمالات برای پیش‌بینی نهایی استفاده می‌شود [۳۴]. وزن‌های بهینه هر مدل نیز توسط Optuna تعیین شدند؛ به طوری که در روش رأی‌گیری نرم، وزن‌های بهینه برای الگوریتم‌های Random Forest برابر با ۱، Gradient Boosting برابر با ۴، XGBoost برابر با ۴، LightGBM برابر با ۲، CatBoost برابر با ۳ و Extra Trees برابر با ۵ تعیین شد. در مقابل، در رأی‌گیری سخت، وزن‌های بهینه مدل‌ها برای الگوریتم Random Forest برابر با ۳، Gradient Boosting برابر با ۲، XGBoost برابر با ۴، LightGBM برابر با ۵، CatBoost برابر با ۲ و Extra Trees برابر با ۵ به دست آمد. استفاده از این روش ترکیبی و تخصیص دقیق وزن‌ها، منجر به بهبود قابل توجهی در دقت پیش‌بینی ارزش مشتریان بانکی شد و عملکرد مدل نهایی را به میزان قابل توجهی افزایش داد. جدول ۳ شامل هایپرپارامترهای بهینه شده هر الگوریتم به همراه بازه جستجو و وزن‌های بهینه شده هر الگوریتم در دو روش رأی‌گیری (نرم و سخت) است.



جدول ۳: هایپرپارامترهای بهینه‌شده هر الگوریتم به همراه بازه جستجو

مقدار بهینه	بازه جستجو	هایپرپارامتر / وزن	الگوریتم
۲۴۴	[۱۰۰-۳۰۰]	n_estimators	Random Forest
۱۶	[۵-۲۰]	max_depth	
۲	[۲-۱۰]	min_samples_split	
۱	[۱-۵]	min_samples_leaf	
۱	[۱-۵]	وزن در رأی‌گیری نرم (Soft Voting)	
۳	[۱-۵]	وزن در رأی‌گیری سخت (Hard Voting)	
۱۴۹	[۱۰۰-۳۰۰]	n_estimators	Gradient Boosting
۰/۲۵۱۱	[۰/۳-۰/۰۱]	learning_rate	
۶	[۳-۱۰]	max_depth	
۴	[۱-۵]	وزن در رأی‌گیری نرم (Soft Voting)	
۲	[۱-۵]	وزن در رأی‌گیری سخت (Hard Voting)	
۱۸۶	[۱۰۰-۳۰۰]	n_estimators	XGBoost
۰/۲۵۴۶	[۰/۳-۰/۰۱]	learning_rate	
۷	[۳-۱۰]	max_depth	
۴	[۱-۵]	وزن در رأی‌گیری نرم (Soft Voting)	
۴	[۱-۵]	وزن در رأی‌گیری سخت (Hard Voting)	
۳۰۰	[۱۰۰-۳۰۰]	n_estimators	LightGBM
۰/۲۳۴۹	[۰/۳-۰/۰۱]	learning_rate	
۱۴	[۵-۱۵]	max_depth	
۲	[۱-۵]	وزن در رأی‌گیری نرم (Soft Voting)	
۵	[۱-۵]	وزن در رأی‌گیری سخت (Hard Voting)	
۲۷۴	[۱۰۰-۳۰۰]	iterations	CatBoost
۰/۲۸۵۲	[۰/۳-۰/۰۱]	learning_rate	
۱۰	[۳-۱۰]	depth	
۳	[۱-۵]	وزن در رأی‌گیری نرم (Soft Voting)	
۲	[۱-۵]	وزن در رأی‌گیری سخت (Hard Voting)	
۲۷۱	[۱۰۰-۳۰۰]	n_estimators	Extra Trees
۲۰	[۵-۲۰]	max_depth	
۲	[۲-۱۰]	min_samples_split	



مقدار بهینه	بازه جستجو	هایپرپارامتر / وزن	الگوریتم
۵	[۱-۵]	وزن در رأی‌گیری نرم (Soft Voting)	
۵	[۱-۵]	وزن در رأی‌گیری سخت (Hard Voting)	

۳-۵- مقایسه با سایر الگوریتم‌های یادگیری ماشین

به منظور مقایسه دقیق عملکرد مدل پیشنهادی با سایر الگوریتم‌های یادگیری ماشین، در این پژوهش ۱۶ الگوریتم پرکاربرد شامل Random Forest، Gradient Boosting، XGBoost، Logistic Regression، Support Vector Machine (SVM)، Extra Trees، CatBoost، LightGBM، Naive Bayes، K-Nearest Neighbors (KNN)، Stochastic Gradient Descent (SGD)، Quadratic Discriminant Analysis (QDA)، Linear Discriminant Analysis (LDA)، Multilayer Perceptron (MLP)، AdaBoost، Tree و GridSearchCV بهینه‌سازی شدند. فرآیند بهینه‌سازی شامل جستجوی گسترده در میان بازه‌های مشخصی از هایپرپارامترها برای یافتن بهترین ترکیب ممکن جهت دستیابی به بالاترین عملکرد و کمترین خطا بوده است. جدول ۴ الگوریتم‌های یادگیری ماشین مورد استفاده، ماهیت آنها و بهترین هایپرپارامترهای بهینه‌شده برای هر کدام را نشان می‌دهد.

جدول ۴: الگوریتم‌های یادگیری ماشین مورد استفاده

هایپرپارامترهای بهینه	توضیح مختصر الگوریتم	الگوریتم
max_depth=۲۰, min_samples_leaf=۱, min_samples_split=۲, n_estimators=۳۰۰	مجموعه‌ای از درخت‌های تصمیم برای کاهش واریانس و افزایش دقت	Random Forest
learning_rate=۰.۱, max_depth=۵, n_estimators=۳۰۰	روش بوستینگ برای ترکیب مدل‌های ضعیف و بهبود تدریجی دقت	Gradient Boosting
learning_rate=۰.۱, max_depth=۷, n_estimators=۳۰۰	نسخه پیشرفته‌ای از Gradient Boosting با سرعت و کارایی بیشتر	XGBoost
learning_rate=۰.۱, max_depth=۱۰, n_estimators=۳۰۰	نسخه بهینه‌شده Gradient Boosting با سرعت بالا و مصرف حافظه کمتر	LightGBM



هایپرپارامترهای بهینه	توضیح مختصر الگوریتم	الگوریتم
depth=۸, iterations=۲۰۰, learning_rate=۰,۱	الگوریتم بوستینگ مخصوص داده‌های طبقه‌ای بدون نیاز به پردازش خاص	CatBoost
max_depth=None, n_estimators=۲۰۰	درخت‌های تصمیم تصادفی بسیار سریع و مقاوم در برابر نویز	Extra Trees
'C=۱۰, kernel='rbf'	طبقه‌بندی با یافتن مرزهای بهینه بین کلاس‌ها در فضای ویژگی‌ها	SVM
'C=۱۰, penalty='l۲', solver='lbfgs'	مدلی خطی برای پیش‌بینی احتمالات تعلق نمونه‌ها به کلاس‌ها	Logistic Regression
(هایپرپارامتر بهینه ندارد)	الگوریتم ساده مبتنی بر احتمالات و تئوری بیس برای طبقه‌بندی	Naive Bayes
'n_neighbors=۳, weights='distance'	طبقه‌بندی نمونه‌ها براساس نزدیک‌ترین همسایگان در فضای ویژگی‌ها	KNN
'alpha=۰,۰۰۰۱, loss='hinge', penalty='l۱'	طبقه‌بندی خطی با استفاده از گرادینان کاهش تصادفی	SGD
max_depth=۱۰, min_samples_split=۲	مدلی مبتنی بر تصمیم‌گیری متوالی برای طبقه‌بندی	Decision Tree
learning_rate=۰,۱, n_estimators=۱۰۰	ترکیب چندین مدل ضعیف برای ایجاد مدلی قوی‌تر با وزندهی مناسب	AdaBoost
activation='relu', hidden_layer_sizes=(۵۰,۵۰)	شبکه عصبی مصنوعی چندلایه با قابلیت یادگیری الگوهای غیرخطی	MLP
(هایپرپارامتر بهینه ندارد)	الگوریتم طبقه‌بندی خطی براساس تحلیل تفکیک خطی بین کلاس‌ها	LDA
(هایپرپارامتر بهینه ندارد)	الگوریتم طبقه‌بندی مبتنی بر تحلیل تفکیک درجه دو بین کلاس‌ها	QDA

همچنین برای ارزیابی دقیق عملکرد مدل‌ها، از تکنیک اعتبارسنجی متقاطع با پنج بخش استفاده شد و نتایج براساس چهار معیار ارزیابی شامل صحت، دقت، بازخوانی، و امتیاز- $F1$ گزارش گردید. برای محاسبه شاخص‌های ارزیابی عملکرد مدل‌ها، از چهار مفهوم اساسی استفاده شده



است. مفهوم اول True Positive (TP) است که بیانگر تعداد مشتریان با ارزشی است که مدل به‌درستی آنها را ارزشمند شناسایی کرده است. مفهوم دوم، True Negative (TN) است که نشان‌دهنده تعداد مشتریان بی‌ارزشی است که مدل به‌درستی آنها را بی‌ارزش پیش‌بینی کرده است. در مقابل این دو مفهوم، False Positive (FP) به تعداد مشتریان بی‌ارزشی اشاره دارد که مدل آنها را به اشتباه به‌عنوان مشتری ارزشمند شناسایی کرده است و مفهوم چهارم، False Negative (FN) است که تعداد مشتریان ارزشمندی را نشان می‌دهد که به اشتباه توسط مدل به‌عنوان بی‌ارزش پیش‌بینی شده‌اند. جدول ۵ شاخص‌های ارزیابی مدل‌های یادگیری ماشین را نشان می‌دهد [۳۵].

جدول ۵: شاخص‌های ارزیابی مدل‌های یادگیری ماشین

شاخص	تعریف	فرمول
صحت	نشان‌دهنده نسبت تعداد نمونه‌هایی است که مدل به‌درستی پیش‌بینی کرده به کل نمونه‌های موجود	$\frac{TP + TN}{TP + FP + FN + TN}$
دقت	نشان‌دهنده نسبت نمونه‌هایی است که مدل به‌درستی برای یک کلاس خاص پیش‌بینی کرده، به کل نمونه‌هایی که مدل برای همان کلاس پیش‌بینی کرده است.	$\frac{TP}{TP + FP}$
بازخوانی	بیانگر نسبت نمونه‌هایی است که مدل به‌درستی برای یک کلاس پیش‌بینی کرده، به تعداد کل نمونه‌های واقعی موجود در آن کلاس.	$\frac{TP}{TP + FN}$
امتیاز F _۱	میانگین هارمونیک دو شاخص دقت و بازخوانی که تعادلی بین این دو معیار ایجاد می‌کند.	$\frac{2 \times Precision \times Recall}{Precision + Recall}$

۴- یافته‌های پژوهش

در این بخش، عملکرد مدل‌های پیشنهادی مبتنی بر رأی‌گیری در دو حالت رأی‌گیری نرم و سخت، با الگوریتم‌های یادگیری ماشین دیگر مقایسه شده است. تمامی مدل‌ها در شرایط یکسان و بر روی سیستمی مجهز به پردازنده Intel Core i7-۱۳۷۰۰H، حافظه رم ۱۶ گیگابایتی و نسخه ۳/۱۲ زبان برنامه‌نویسی پایتون اجرا شده‌اند. نتایج به‌دست‌آمده از این ارزیابی و مقایسه در جدول ۶ ارائه شده است.



جدول ۶: مقایسه عملکرد مدل‌ها


امتیاز F1	بازخوانی (Recall)	دقت (Precision)	صحت (Accuracy)	مدل
۰/۹۴۰۷۶	۰/۹۱۱۲۴	۰/۹۷۵۶۲	۰/۹۴۲۵۹	Voting (Hard)
۰/۹۴۲۲۰	۰/۹۰۶۲۳	۰/۹۷۷۱۳	۰/۹۴۱۵۰	Voting (Soft)
۰/۹۳۶۸۹	۰/۹۰۴۰۹	۰/۹۶۳۲۱	۰/۹۳۷۱۴	Random Forest
۰/۹۳۴۴۳	۰/۹۱۴۱۱	۰/۹۵۶۰۴	۰/۹۳۴۹۶	Gradient Boosting
۰/۹۳۴۸۰	۰/۹۰۳۳۷	۰/۹۶۸۶۹	۰/۹۳۶۰۵	XGBoost
۰/۹۳۵۳۲	۰/۹۱۰۵۲	۰/۹۶۱۷۲	۰/۹۳۶۰۵	LightGBM
۰/۹۳۲۵۹	۰/۸۹۲۶۳	۰/۹۷۶۶۴	۰/۹۳۴۶۰	CatBoost
۰/۹۳۵۲۰	۰/۸۹۵۵۰	۰/۹۸۲۸۹	۰/۹۳۶۷۸	Extra Trees
۰/۸۷۰۰۳	۰/۷۹۸۸۷	۰/۹۵۵۶۴	۰/۸۷۹۰۰	SVM
۰/۸۳۸۸۹	۰/۸۱۳۱۹	۰/۸۶۶۶۱	۰/۸۴۱۵۸	Logistic Regression
۰/۷۴۹۶۲	۰/۶۱۶۳۵	۰/۹۵۷۵۹	۰/۷۹۱۴۳	Naive Bayes
۰/۸۹۶۸۴	۰/۸۲۵۳۶	۰/۹۸۲۲۱	۰/۹۰۳۷۱	KNN
۰/۸۳۹۵۴	۰/۷۷۸۱۳	۰/۸۶۵۶۴	۰/۸۲۴۸۷	SGD
۰/۸۹۷۶۶	۰/۸۷۵۴۷	۰/۹۲۰۶۴	۰/۹۰۱۵۴	Decision Tree
۰/۸۹۷۱۰	۰/۸۶۱۱۵	۰/۹۳۶۲۸	۰/۸۹۹۷۲	AdaBoost
۰/۸۸۶۹۲	۰/۸۱۸۹۱	۰/۹۲۴۳۰	۰/۸۸۹۱۸	MLP
۰/۸۲۲۹۲	۰/۷۹۸۸۷	۰/۸۴۹۰۴	۰/۸۲۵۵۹	LDA
۰/۷۲۶۳۳	۰/۵۸۴۸۵	۰/۹۶۰۶۱	۰/۷۷۶۹۰	QDA

براساس جدول نتایج به دست آمده از ارزیابی ۱۶ الگوریتم یادگیری ماشین و مقایسه آنها با مدل‌های پیشنهادی در این پژوهش، می‌توان عملکرد بسیار مطلوب مدل‌های پیشنهادی مبتنی بر روش رأی‌گیری را به روشنی مشاهده نمود. مدل رأی‌گیری سخت با صحت برابر با ۰/۹۴۲۵۹، بهترین عملکرد را از نظر صحت نسبت به تمامی الگوریتم‌ها داشته و توانسته است به بالاترین نرخ تشخیص صحیح در پیش‌بینی ارزش مشتریان بانکی دست یابد. این مدل از نظر بازخوانی نیز بهترین نتیجه (۰/۹۱۱۲۴) را ارائه داده که بیانگر توانایی بالا در شناسایی تعداد بیشتری از مشتریان ارزشمند واقعی است و به‌طور قابل توجهی نرخ مشتریان ارزشمند



از دست‌رفته^۱ را کاهش داده است. از سوی دیگر، مدل رأی‌گیری نرم نیز عملکرد بسیار قوی و قابل‌توجهی را نشان داده است. این مدل توانسته با دستیابی به بالاترین دقت معادل ۰/۹۷۷۱۳، نشان دهد که پیش‌بینی‌های این مدل در تعیین مشتریان ارزشمند، با کمترین خطا همراه است. علاوه بر این، مدل رأی‌گیری نرم در معیار امتیاز F_1 نیز با کسب بالاترین مقدار (۰/۹۴۲۲۰) نسبت به سایر مدل‌ها، به بهترین تعادل بین دقت و بازخوانی دست یافته است. این امر نشان می‌دهد که مدل رأی‌گیری نرم نه تنها مشتریان ارزشمند را به خوبی شناسایی کرده است بلکه در عین حال تعداد موارد پیش‌بینی نادرست آن به شدت کاهش یافته است. در مقایسه با الگوریتم‌های کلاسیک و قدرتمندی مانند Random Forest، Gradient Boosting، XGBoost، LightGBM و CatBoost که همواره جزو دقیق‌ترین و قوی‌ترین مدل‌ها در مسائل یادگیری ماشین طبقه‌بندی محسوب می‌شوند، باز هم مدل‌های پیشنهادی مبتنی بر رأی‌گیری نرم و سخت به صورت محسوس عملکرد بهتری نشان داده‌اند. برای مثال، مدل Random Forest که بهترین صحت (۰/۹۳۷۱۴) را در بین مدل‌های تکی داشته است، باز هم عملکرد آن نسبت به مدل رأی‌گیری سخت (۰/۹۴۲۵۹) پایین‌تر است. همچنین، مدل Extra Trees که بیشترین دقت (۰/۹۸۲۸۹) را در بین الگوریتم‌های منفرد داشته است، نتوانسته در صحت و امتیاز F_1 از مدل‌های پیشنهادی عبور کند. همچنین، مدل‌های سنتی‌تر نظیر Logistic Regression، Naive Bayes، KNN، SGD و الگوریتم‌های مبتنی بر تحلیل تفکیک نظیر LDA و QDA با اختلاف معناداری در همه معیارهای ارزیابی، عملکرد پایین‌تری نسبت به مدل‌های پیشنهادی داشته‌اند. به طور مثال، الگوریتم Naive Bayes با کمترین مقدار بازخوانی (۰/۶۱۶۳۵) و QDA با پایین‌ترین صحت (۰/۷۷۶۹۰) و امتیاز F_1 (۰/۷۲۶۳۳) به وضوح نشان می‌دهند که قادر به رقابت با مدل پیشنهادی نیستند و اختلاف چشمگیری در عملکرد دارند.

^۱ False Negative



شکل ۶. مقایسه مدل‌های یادگیری ماشین

همان‌طور که در شکل ۶ نشان داده شده است، مقایسه دقیق و جامع نتایج نشان می‌دهد که ترکیب الگوریتم‌ها به روش رأی‌گیری نرم و سخت و استفاده از بهینه‌سازی دقیق و هدفمند وزن‌ها و هایپرپارامترها باعث ایجاد مدل‌هایی شده است که نه تنها نسبت به الگوریتم‌های منفرد عملکرد بالاتری دارند، بلکه به شکل محسوس‌تری بهبود یافته و عملکردی قدرتمند و باثبات را در تمامی معیارهای ارزیابی به نمایش گذاشته‌اند. این امر بیانگر مزیت چشمگیر رویکرد پیشنهادی در این پژوهش است که موجب دستیابی به حداکثر دقت و حداقل خطا در پیش‌بینی ارزش مشتریان بانکی شده است.

۵- بحث و نتیجه‌گیری

نتایج حاصل از پیاده‌سازی و ارزیابی مدل ترکیبی پیشنهادی در این پژوهش، گویای آن است که استفاده هم‌زمان از چند الگوریتم قدرتمند یادگیری ماشین همراه با رأی‌گیری وزنی و بهینه‌سازی پارامترها، به شکل معناداری موجب ارتقاء دقت طبقه‌بندی ارزش مشتریان بانکی شده است. مدل‌های پیشنهادی رأی‌گیری سخت و نرم توانستند به ترتیب با صحت ۹۴/۲۶ درصد و ۹۴/۱۵ درصد و همچنین بالاترین مقادیر امتیاز $F1$ (۰/۹۴۰۷۶ و ۰/۹۴۲۲۰) در بین تمامی مدل‌های آزمایش‌شده، عملکرد بهتری از خود نشان دهند. این نتایج بیانگر آن است که تلفیق هوشمند مدل‌های پایه، به‌ویژه زمانی که وزن مشارکت آنها به‌صورت بهینه تنظیم شود،



می‌تواند نتایج فراتر از هریک از الگوریتم‌های منفرد ارائه دهد. از نظر مقایسه با مطالعات پیشین، یافته‌های این تحقیق هم‌راستا با نتایج پژوهش‌های جدیدی مانند گلال و همکاران (۲۰۲۴) [۲۳]، چن شوافنگ و همکاران (۲۰۲۴) [۷] و یائو و همکاران (۲۰۲۲) [۲۵] است که نشان داده‌اند مدل‌های ترکیبی و مبتنی بر رأی‌گیری می‌توانند عملکردی فراتر از مدل‌های منفرد داشته باشند. با این حال، پژوهش حاضر با بهره‌گیری از تنظیم وزن رأی‌گیری به کمک Optuna، انتخاب ویژگی هدفمند و متعادل‌سازی داده با ADASYN، گامی فراتر نهاده و مدلی ارائه کرده است که از حیث جامعیت و دقت عملیاتی، خلأهای باقی‌مانده در مطالعات گذشته را به صورت محسوس پوشش می‌دهد.

در پاسخ به پرسش اول تحقیق، نتایج به‌روشنی نشان می‌دهد که مدل ترکیبی پیشنهادی در تمامی شاخص‌های ارزیابی نسبت به الگوریتم‌های منفرد عملکرد بهتری دارد. برای نمونه، مدل ترکیبی مبتنی بر رأی‌گیری سخت از مدل Random Forest که دقت بالایی دارد نیز بهتر عمل کرده است. در پاسخ به پرسش دوم، مشاهده شد که رأی‌گیری نرم با دقت (۰/۹۷۷۱۳) و $F1$ بیشتر نسبت به رأی‌گیری سخت، تعادل بهتری میان بازخوانی و دقت برقرار کرده و مناسب‌تر برای کاربردهای واقعی بانکی است. پرسش سوم درباره استفاده از ADASYN نیز پاسخ مثبتی دارد؛ این روش با ایجاد تعادل در داده‌ها، توانست به‌طور مشخص نرخ شناسایی مشتریان باارزش پایین را افزایش داده و از شیب یادگیری مدل‌ها بکاهد. پرسش چهارم نیز با تحلیل ویژگی‌های منتخب به کمک الگوریتم Random Forest پاسخ داده شد؛ ویژگی‌هایی نظیر «جمع کل واریزی‌ها»، «کل تراکنش‌های غیرحضور» و «تعداد دفعات مراجعه» بیشترین اثر را در پیش‌بینی ارزش مشتری داشتند. نهایتاً، پاسخ به پرسش پنجم به‌وضوح نشان داد که مدل پیشنهادی در مقایسه با الگوریتم‌های سنتی مانند Logistic Regression، Naive Bayes و SVM، برتری مطلق در تمامی معیارهای ارزیابی دارد. از منظر اجرایی، نتایج این پژوهش نشان می‌دهد که مدل ترکیبی پیشنهادی می‌تواند به‌عنوان یک ابزار تصمیم‌یار کارآمد برای مدیران بانک‌ها مورد استفاده قرار گیرد. این مدل قادر است مشتریان باارزش را با دقت بسیار بالا شناسایی کند و از این طریق، امکان طراحی سیاست‌های بازاریابی هدفمند، تخصیص هوشمند منابع و تمرکز بر حفظ مشتریان سودآور را فراهم سازد. همچنین، شناسایی دقیق مشتریان کم‌ارزش می‌تواند به کاهش هزینه‌های بازاریابی، مدیریت ریسک اعتباری و بهبود بازده سرمایه‌گذاری کمک کند.



مدل پیشنهادی با عملکرد پایدار و انعطاف‌پذیری بالا، قابلیت پیاده‌سازی مستقیم در سامانه‌های موجود بانکها از جمله سیستم‌های مدیریت ارتباط با مشتری را دارد و می‌تواند در تصمیم‌گیری‌های استراتژیک و عملیاتی روزانه به‌عنوان ابزاری هوشمند و قابل اتکا ایفای نقش کند.

از نظر اعتبار نتایج، اقدامات متعددی در طراحی پژوهش لحاظ شده تا از دقت و قابلیت اعتماد یافته‌ها اطمینان حاصل شود. استفاده از داده‌های واقعی بانکی، بهره‌گیری از روش‌های بهینه‌سازی هایپرپارامترها با الگوریتم Optuna، و اعمال اعتبارسنجی متقاطع برای سنجش عملکرد مدل‌ها، از جمله مهم‌ترین عوامل تقویت‌کننده اعتبار نتایج بوده‌اند. همچنین، ارزیابی مدل‌ها با استفاده از چندین معیار مکمل مانند صحت، بازخوانی، و امتیاز F1، به‌جای تکیه صرف بر یک شاخص، باعث افزایش جامعیت تحلیل عملکرد شده است. مقایسه مدل پیشنهادی با ۱۶ الگوریتم متنوع نیز نشان می‌دهد که نتایج به‌دست‌آمده در برابر جایگزین‌های رایج از پایداری بالاتری برخوردار بوده‌اند. با این حال، باید توجه داشت که اعتبار نتایج به داده‌های خاص استفاده‌شده در این پژوهش وابسته است و ممکن است در محیط‌های بانکی با ساختارهای داده‌ای متفاوت، عملکرد مدل نیاز به تنظیم مجدد داشته باشد. از این رو، تعمیم کامل نتایج به سایر بانکها نیازمند بررسی‌های تکمیلی در مطالعات آتی است. با وجود نتایج قابل‌قبول مدل پیشنهادی در طبقه‌بندی ارزش مشتریان بانکی، این پژوهش نیز همچون سایر مطالعات داده‌محور با محدودیت‌هایی مواجه بوده است که لازم است در تفسیر نتایج و توسعه‌های آتی مدنظر قرار گیرند. نخست، داده‌های مورد استفاده تنها متعلق به یک بانک و یک بازه زمانی خاص (یک‌ساله) بوده‌اند که ممکن است بر قابلیت تعمیم‌پذیری مدل تأثیرگذار باشد. نتایج به‌دست‌آمده ممکن است در سایر بانکها یا در داده‌هایی با ساختار متفاوت عملکرد مشابهی نداشته باشند. دوم، اگرچه تکنیک ADASYN برای مدیریت عدم‌توازن کلاس‌ها استفاده شده، اما ایجاد نمونه‌های مصنوعی می‌تواند در برخی شرایط باعث افزایش نویز یا تکرار الگوهای غیرواقعی در داده‌ها شود. همچنین، مدل پیشنهادی صرفاً بر پایه داده‌های ساختاریافته عددی طراحی شده و از داده‌های متنی یا کیفی مانند تعاملات مشتری، نظرات یا اطلاعات رفتاری غیرعددی بهره‌نبرده است. از سوی دیگر، انتخاب الگوریتم‌های پایه و پارامترهای آن‌ها بر مبنای تجربیات قبلی و بهینه‌سازی محلی انجام شده و امکان دارد در داده‌های متفاوت، نیازمند



بازتنظیم یا بازطراحی باشد. نهایتاً، این مطالعه به بررسی رابطه آماری و الگوریتمی متغیرها پرداخته و تأثیر عوامل بیرونی مانند سیاست‌های اعتباری، رفتار رقبا یا تغییرات اقتصادی در نظر گرفته نشده است.

۶- پیشنهادهای پژوهش

با توجه به نتایج حاصل از این پژوهش و تحلیل عملکرد مدل ترکیبی پیشنهادی، مجموعه‌ای از پیشنهادها کاربردی و پژوهشی به‌منظور بهره‌برداری بهتر از یافته‌ها و توسعه مطالعات آتی ارائه می‌شود.

از منظر کاربردی، پیشنهاد می‌شود بانک‌ها و مؤسسات مالی از مدل یادگیری ماشین ترکیبی مبتنی بر رأی‌گیری وزنی که در این تحقیق طراحی شده، در چارچوب سیستم‌های مدیریت ارتباط با مشتری بهره‌گیرند. پیاده‌سازی این مدل می‌تواند در بهبود تصمیم‌گیری‌های مرتبط با ارزیابی ارزش مشتری، تخصیص بهینه منابع، و طراحی خدمات و پیشنهادها شخصی‌سازی شده بسیار مؤثر باشد. استفاده از تکنیک ADASYN نیز برای متوازن‌سازی داده‌های نامتوازن، راهکاری مؤثر جهت شناسایی دقیق‌تر مشتریان با ارزش پایین‌تر ارائه می‌دهد که معمولاً در تحلیل‌های سنتی نادیده گرفته می‌شوند. همچنین، مدل پیشنهادی قابلیت تلفیق با داشبوردهای مدیریتی را دارد و می‌تواند به‌عنوان ابزاری هوشمند در بهینه‌سازی استراتژی‌های بازاریابی، حفظ مشتریان سودآور، و پیش‌بینی رفتار مشتریان عمل کند.

از منظر علمی و پژوهشی نیز، این تحقیق مسیری برای توسعه آتی مطالعات فراهم می‌سازد. نخست، پیشنهاد می‌شود از مدل ترکیبی ارائه‌شده در این پژوهش در سایر صنایع داده‌محور مانند بیمه، تجارت الکترونیک و خدمات درمانی استفاده شود تا میزان تعمیم‌پذیری و کارایی آن در حوزه‌های مختلف ارزیابی شود. دوم، استفاده از الگوریتم‌های عمیق‌تر مانند شبکه‌های عصبی بازگشتی یا مدل‌های یادگیری تقویتی، می‌تواند توان پیش‌بینی و تحلیل رفتار مشتری را در محیط‌های پویا تر افزایش دهد. سوم، پیشنهاد می‌شود در پژوهش‌های آتی، از داده‌های غیرساختاریافته نظیر متن‌های ارتباطی مشتریان، پیام‌ها و تحلیل احساسات نیز بهره‌گرفته شود تا مدل‌های پیش‌بینی ارزش مشتری به ابعاد رفتاری و کیفی نیز مجهز گردند.



۷- منابع

- [۱] Dadashi, A., Hamidzadeh, A., & Sanavi Fard, R. (۲۰۲۲). Designing a content marketing model for the banking industry to increase the target market share. *Management Research in Iran*, ۲۶(۲), ۱۱۶-۱۴۲. <https://doi.org/10.1001/1.2322200.1401.26.2.6.0>. [In Persian]
- [۲] Ullah, A., Mohmand, M. I., Hussain, H., Johar, S., Khan, I., Ahmad, S., Mahmoud, H. A., & Huda, S. (۲۰۲۳). Customer Analysis Using Machine Learning-Based Classification Algorithms for Effective Segmentation Using Recency, Frequency, Monetary, and Time. *Sensors*, ۲۳(۶), ۳۱۸۰. <https://doi.org/10.3390/s23063180>.
- [۳] Singh, P. P., Anik, F. I., Senapati, R., Sinha, A., Sakib, N., & Hossain, E. (۲۰۲۳). Investigating customer churn in banking: A machine learning approach and visualization app for data science and management. *Data Science and Management*, ۷(۱). <https://doi.org/10.1016/j.dsm.2023.09.002>.
- [۴] Ahmed, U., Srivastava, G., & Lin, J. C.-W. (۲۰۲۲). Reliable customer analysis using federated learning and exploring deep-attention edge intelligence. *Future Generation Computer Systems*, ۱۲۷, ۷۰-۷۹. <https://doi.org/10.1016/j.future.2021.08.028>.
- [۵] Sun, Y., Liu, H., & Gao, Y. (۲۰۲۳). Research on customer lifetime value based on machine learning algorithms and customer relationship management analysis model. *Heliyon*, ۹(۲), e۱۳۳۸۴. Sciencedirect. <https://doi.org/10.1016/j.heliyon.2023.e13384>.
- [۶] Galal, M., Rady, S., & Aref, M. (۲۰۲۴a). Enhancing Customer Churn Prediction in Digital Banking Using Hybrid Meta-Learners and Stacking Ensemble Modeling. ۱۴۳-۱۴۸. <https://doi.org/10.1109/airc61399.2024.10671880>.
- [۷] Chen Shuofeng, Karim, A. M., & Li, L. (۲۰۲۴). A Multiclass Ensemble Learning Approach for Predicting Customer Churn in Commercial Banks. *International Journal of Academic Research in Progressive Education and Development*, ۱۳(۴), ۷۸۷-۸۰۴. <http://dx.doi.org/10.6007/IJARPE/v13-j4/230443>.
- [۸] Yao, J., Wang, Z., Wang, L., Liu, M., Jiang, H., & Chen, Y. (۲۰۲۲). Novel hybrid ensemble credit scoring model with stacking-based noise detection and weight assignment. *Expert Systems with Applications*, ۱۹۸, ۱۱۶۹۱۳. <https://doi.org/10.1016/j.eswa.2022.116913>.
- [۹] Kehinde Josephine Olowe, Ngozi Linda Edoh, Jean, S., & Olamijuwon, J. (۲۰۲۴). Review of predictive modeling and machine learning applications in financial service analysis. *Computer Science & IT Research Journal*, ۵(۱۱). <https://doi.org/10.51094/csitjr.v0i11.1731>.
- [۱۰] Birant, D. (۲۰۲۰). Data Mining in Banking Sector Using Weighted Decision Jungle Method. *Data Mining - Methods, Applications and Systems*. <https://doi.org/10.5772/intechopen.91836>.



- [۱۱] Dawood, E. A. E., Elfakhrany, E., & Maghraby, F. A. (۲۰۱۹). Improve Profiling Bank Customer's Behavior Using Machine Learning. IEEE Access, ۷, ۱۰۹۳۲۰–۱۰۹۳۲۷. <https://doi.org/10.1109/access.2019.2934644>.
- [۱۲] Deloitte. (۲۰۲۲). AI and risk management in banking: Navigating challenges and seizing opportunities. Deloitte Insights. Retrieved from <https://www۲.deloitte.com/xe/en/pages/financial-services/articles/ai-in-banking.html>.
- [۱۳] McKinsey & Company. (۲۰۲۱). The future of personalization in banking. Retrieved from <https://www.mckinsey.com/industries/financial-services/our-insights/reimagining-personalized-banking-through-ai>.
- [۱۴] Gheysari, K., Hoseyni, M., Azar, A., & Khademi, S. (۲۰۲۱). Investigate the factors affecting consumer brand preferences by considering the life cycle of customers in banking sector. Management Research in Iran, ۲۵(۴), ۲۷–۴۴. <https://doi.org/10.1016/j.232220.1400.25.4.2.8>. [In Persian]
- [۱۵] Jafarnejad Chaghoshi, A., Rezasoltani, A. and Khani, A. M. (۲۰۲۴). Unleashing the Power of Ensemble Learning: Predicting National Ranks in Iran's University Entrance Examination. Industrial Management Journal, ۱۶(۳), ۴۵۷-۴۸۱. doi: [10.22059/ijm.2024.381521.1008178](https://doi.org/10.22059/ijm.2024.381521.1008178).
- [۱۶] Amirhassankhani H, Toloie Eshlaghy A, Radfar R, Pourebrahimi A. Presenting a hybrid model based on machine learning for the classification of banking and insurance industry common customers. J Prod Manag. ۲۰۲۴;۶۸:۵۳-۸۰. [In Persian]
- [۱۷] Hosseini, S. , Motadel, M. and Toloie Eshlaghy, A. (۲۰۲۴). Developing a customer relationship model based on the competitive advantage of the Markov chain approach and customer classification using customer lifetime value (case study of Tejarat Bank). Modern Research in Decision Making, ۹(۴), ۳۳-۶۶. [In Persian]
- [۱۸] Najafi, A. and Akhondzadeh Noughabi, E. (۲۰۲۴). Pattern Mining of customer dynamics through different customer value states by using sequence pattern mining and big data analytics. Modern Research in Decision Making, ۹(۴), ۶۸-۹۳. [In Persian]
- [۱۹] Aghakhani Bezdi Langari, A. and Hasani , A. (۲۰۲۳). Customer Churn Analysis Based on the Data-mining Approach: Hybrid Algorithm Incorporates Decision Tree and Bayesian Network. New Marketing Research Journal, ۱۳(۲), ۱-۲۲. doi: [10.22108/nmrj.2023.130706.2797](https://doi.org/10.22108/nmrj.2023.130706.2797). [In Persian]
- [۲۰] Soltani, M., Khatami Firouzabadi, S. M. A. , Amiri, M. and Hajian Heidary, M. (۲۰۲۳). Proposing an integrated approach for omnichannel demand forecasting using machine learning-time series clustering with dynamic time warping algorithm and artificial neural networks. Research in Production and Operations Management, ۱۴(۱), ۱۲۱-۱۴۰. doi: [10.22108/pom.2023.136202.1485](https://doi.org/10.22108/pom.2023.136202.1485). [In Persian]



- [۲۱] Zhu, H. (۲۰۲۴). Bank Customer Churn Prediction with Machine Learning Methods. ۶۹(۱), ۲۳–۲۹. <https://doi.org/10.54204/2704-1169/69/2023.0773>.
- [۲۲] He, C., & Chris. (۲۰۲۴). A novel classification algorithm for customer churn prediction based on hybrid Ensemble-Fusion model. Scientific Reports, ۱۴(۱), ۱–۲۵. <https://doi.org/10.1038/s41598-024-71178-x>.
- [۲۳] Galal, M., Rady, S., & Aref, M. (۲۰۲۴b). Enhancing Machine Learning Engineering For Predicting Youth Loyalty In Digital Banking Using A Hybrid Meta-Learners. International Journal of Intelligent Computing and Information Sciences/International Journal of Intelligent Computing and Information Sciences, ۲۴(۲), ۲۸–۴۰. <https://doi.org/10.21604/ijicis.2024.283191.1334>.
- [۲۴] Mohammad, E., Dekamini Fatemeh, Amir, M., Khazaei Moein, Cristi, S., Ramona, B., & Dorin, F. R. (۲۰۲۳). Evaluating the performance of machine learning algorithms in predicting the best bank customers. Annals of the University of Craiova Mathematics and Computer Science Series, ۵۰(۲), ۴۶۴–۴۷۵. <https://doi.org/10.52846/ami.v50.i2.1781>.
- [۲۵] Yao, J., Wang, Z., Wang, L., Zhang, Z., Jiang, H., & Yan, S. (۲۰۲۲). A hybrid model with novel feature selection method and enhanced voting method for credit scoring. Journal of Intelligent & Fuzzy Systems, ۴۲(۳), ۲۵۶۵–۲۵۷۹. <https://doi.org/10.3233/jifs-211828>.
- [۲۶] Zhang, W., Yang, D., & Zhang, S. (۲۰۲۱). A new hybrid ensemble model with voting-based outlier detection and balanced sampling for credit scoring. Expert Systems with Applications, ۱۷۴, ۱۱۴۷۴۴. <https://doi.org/10.1016/j.eswa.2021.114744>.
- [۲۷] Mitra, R., Bajpai, A., & Biswas, K. (۲۰۲۳). ADASYN-assisted machine learning for phase prediction of high entropy carbides. Computational Materials Science, ۲۲۳, ۱۱۲۱۴۲. <https://doi.org/10.1016/j.commatsci.2023.112142>.
- [۲۸] Grus, J. (۲۰۱۹). DATA SCIENCE FROM SCRATCH: first principles with python. O'Reilly Media.
- [۲۹] Mehregan, M. R., & Khani, A. M. (۲۰۲۴). Improving organizational performance: The role of supply chain ۴.۰ and financing in reducing supply chain risk. Journal of International Business Administration, ۷(۳), ۳۹–۵۹. <https://doi.org/10.22034/jiba.2024.70005.216>.
- [۳۰] Jafarnejad Chaghoshi, A., Rezasoltani, A. and Khani, A. M. (۲۰۲۴). Unleashing the Power of Ensemble Learning: Predicting National Ranks in Iran's University Entrance Examination. Industrial Management Journal, ۱۶(۳), ۴۵۷–۴۸۱. [doi: 10.22059/ijm.2024.381021.10.8178](https://doi.org/10.22059/ijm.2024.381021.10.8178). [In Persian].
- [۳۱] Abdulsadig, R. S., & Rodriguez-Villegas, E. (۲۰۲۴). A comparative study in class imbalance mitigation when working with physiological signals. Frontiers in Digital Health, ۶. <https://doi.org/10.3389/fdgth.2024.1377160>.
- [۳۲] Parra-Ullauri, J., Zhang, X., Bravalheri, A., Reza Nejabati, & Dimitra Simeonidou. (۲۰۲۳). Federated Hyperparameter Optimisation with Flower and



- Optuna. Proceedings of the 37th ACM/SIGAPP Symposium on Applied Computing, ۱۲۰۹–۱۲۱۶. <https://doi.org/10.1145/3505776.3577847>.
- [۳۳] Sami Hadhri, Mondher Hadji, & Walid Labidi. (۲۰۲۴). A voting ensemble classifier for stress detection. Journal of Information and Telecommunication, ۱–۱۸. <https://doi.org/10.1080/24751839.2024.2306786>.
- [۳۴] Mimusa Azim Mim, Nazia Majadi, & Mazumder, P. (۲۰۲۴). A soft voting ensemble learning approach for credit card fraud detection. Heliyon, e۲۵۴۶۶–e۲۵۴۶۶. <https://doi.org/10.1016/j.heliyon.2024.e25466>.
- [۳۵] Jafarnejad, A., Rezasoltani, A., & Khani, A. M. (۲۰۲۵). Predicting heart disease using automated machine learning based on genetic algorithms. Journal of Information Technology Management, ۱۷(۲), ۹۱–۱۲۲. <https://doi.org/10.220۵۹/jitm.2024.382056.3829>.