

پیش‌بینی ریسک اعتبار با دسته‌بندی میزان تأخیر در بازپرداخت وام در پلتفرم‌های وام‌دهی همتابه‌همتا

تاریخ دریافت: ۱۴۰۱/۰۶/۱۶

تاریخ پذیرش: ۱۴۰۱/۰۷/۱۸

کد مقاله: ۷۲۱۴۱

سید محمدرضا قریشی^{۱*}، کورش عشقی^۲

چکیده

انسان‌ها برای بهبود کیفیت زندگی و شرکت‌ها به منظور توسعه اقتصادی و افزایش قدرت رقابتی به منابع مالی نیاز دارند. دریافت وام یکی از شیوه‌های رایج تأمین مالی است. وام‌دهی همتابه‌همتا که به عنوان «وام‌دهی بازار» و «وام‌دهی اجتماعی» نیز شناخته می‌شود، نوع جدیدی از واسطه‌گری میان وام‌دهندگان و وام‌گیرندگان می‌باشد که نقش مؤسسات مالی (نظیر بانک‌ها) را به عنوان واسطه از بین می‌برد و به موجودیت‌ها (افراد یا کسب‌وکارها) این امکان را می‌دهد که مستقیماً از سایر موجودیت‌ها وام دریافت کنند. در این مطالعه ابتدا برای افزایش رضایت وام‌دهندگان، مدل یادگیری ماشین قدرتمند و تفسیرپذیری برای پیش‌بینی ریسک عدم‌پرداخت وام‌گیرندگان ارائه شده و سپس برای کمک به وام‌گیرندگان جهت بهبود امتیاز اعتباری تخصیص داده‌شده و تغییر آینده مورد انتظار، از توضیحات خلاف‌واقع استفاده شده است. قدرت غربال‌گری این مدل نسبت به سایر مدل‌های موجود در ادبیات به کمک مجموعه داده پلتفرم «لندینگ کلاب» به عنوان مطالعه موردی بررسی شد. نتایج نشان می‌شود مدل ارائه‌شده هم در حالت دو کلاسه قدرت غربال‌گری بالایی دارد و هم در حالت چهار کلاسه می‌تواند متجر به هزینه‌های کمتری شود.

واژگان کلیدی: وام‌دهی همتابه‌همتا، ارزیابی اعتبار، یادگیری ماشینی با نظارت، توضیحات خلاف‌واقع

۱- دانشجوی کارشناسی ارشد، رشته مهندسی صنایع، دانشگاه صنعتی شریف؛ (نویسنده مسئول) ghoreishi.smr@gmail.com

۲- استاد و عضو هیئت علمی مهندسی صنایع، دانشکده مهندسی صنایع، دانشگاه صنعتی شریف

۱- مقدمه

امروزه «وام» واژه‌ی آشنایی برای اکثریت مردم می‌باشد که در زندگی روزمره برای فراهم کردن حداقل امکانات لازم مخصوصاً در شرایط نابسامان اقتصادی با آن زیاد سرو کار دارند. همچنین ایده‌پردازان در مرحله ایجاد و سپس بلوغ شرکت‌های نوپا، مؤسسات تولیدی و خدماتی برای توسعه مداوم همگام با پیشرفت‌های صنعت و حتی دولت‌ها برای اجرای طرح‌های کلان در کشور، همواره باید سناریو اخذ وام را مورد بررسی قرار دهند. با هدف پاسخگویی به این میزان از تقاضا، افراد و نهادهای متنوعی به صورت مستقیم یا به عنوان واسطه وام‌های مختلفی را اعطا می‌کنند. با این وجود بزرگ‌ترین و معتبرترین اعطاکندگانی همان بانک‌ها و مؤسسات مالی هستند که تنها سازمان‌های رسمی موجود می‌باشند.

پیشرفت‌های فناوری طی دهه‌های اخیر کسب‌وکارهای متعددی را متحول کرده است و اکنون تلاش در ایجاد انقلابی عظیم در صنعت وام‌دهی دارد. این صنعت از جمله صنایعی است که به سبب فین‌تک (فناوری مالی) سریع‌تر و ساده‌تر شده است. از دیرباز، هفته‌ها یا ماه‌ها طول می‌کشید تا یک وام تأیید شود. اما به کمک هوش مصنوعی برای ارزیابی صلاحیت وام‌گیرنده هنگام بازپرداخت وام، وام‌دهندگان فین‌تک اغلب می‌توانند وام‌ها را طی ۲۴ ساعت پردازش، تأیید و پرداخت کنند. این فناوری می‌تواند برای ارائه وام‌های کوتاه‌مدت به مشاغل کوچک استفاده شود یا بر خلاف بانک‌های مرسوم که برای اعطای درخواست وام به مشتریان دیگر به سپرده‌گذاری وام‌گیرندگان نیاز دارند، وام‌دهی هم‌تابه‌همتا را امکان‌پذیر کند.

اصطلاح «همتابه‌همتا» از حوزه معماری شبکه‌های رایانه‌ای نشأت گرفته شده است و بیانگر تعامل مستقیم بین دو موجودیت، بدون نیاز به یک واسطه مرکزی می‌باشد. وام‌دهی همتابه‌همتا یا «فرد به فرد» که به عنوان «وام‌دهی بازارگاه»، «وام‌دهی اجتماعی» یا «وام‌دهی جمعی» نیز شناخته می‌شود، نوع جدیدی از واسطه‌گری می‌باشد که نقش مؤسسات مالی را به عنوان واسطه از بین می‌برد و به موجودیت‌ها (افراد یا کسب‌وکارها) این امکان را می‌دهد که مستقیماً از سایر موجودیت‌ها وام دریافت کنند. خدمات وام همتابه‌همتا برای اولین بار در سال ۲۰۰۵ در انگلستان و ایالات متحده آغاز شد و تقاضا برای خدمات در طول بحران نقدینگی ۲۰۰۸-۲۰۰۹ به طور تصاعدی افزایش یافت. (گونزالس، ۲۰۲۰)

سیستم وام‌دهی همتابه‌همتا مزایای رقابتی متعددی نسبت به تأمین‌کنندگان فعلی همچون بانک‌ها دارد که از جمله آن می‌توان به (۱) ارائه نرخ بازدهی بهتر از سپرده‌های بانکی و هزینه‌های نسبتاً کم برای وام‌گیرندگان، (۲) اعطای اعتبار به دسته‌ای از وام‌گیرندگان که امتیاز کافی برای اخذ وام‌های بانکی را ندارند (۳) تصور اینکه وام‌دهی همتابه‌همتا مسئولیت‌پذیرتر و دارای ارزش اجتماعی بیشتری نسبت به بانکداری معمولی است و (۴) نوآوری فنی بهبود کیفیت و سرعت خدمات به وام‌گیرندگان و وام‌دهندگان، اشاره کرد. لذا در این سیستم وام‌دهی می‌توان خدمات با کیفیت‌تری را هم به وام‌گیرندگان (یک فرایند ساده درخواست وام با یک تصمیم سریع و یک درگاه شفاف و انعطاف‌پذیر برای نظارت بر بازپرداخت‌ها و تعهدات معوق آنها) و هم به وام‌دهندگان (برای مدیریت وام آنها و پیگیری وضعیت فعلی سرمایه‌گذاری آنها) ارائه داد (میلن و پاربوتیه، ۲۰۱۶).

استارت‌آپ «بیت وام» اولین استارت‌آپی بود که در ایران در سال ۱۳۹۴ در حوزه وام‌دهی همتابه‌همتا شروع به فعالیت کرد، اما فعالیتش کاملاً متوقف شد. (معدنچی زاج و حیدرزاده اقدم ۱۳۹۸) اکنون در ایران هیچ پلتفرم وام‌دهی همتابه‌همتایی فعالیت نمی‌کند و بانک مرکزی اجازه ارائه چنین وام‌هایی را به دلیل خطرات ناشی از خلق پول توسط نهادهایی غیر از بانک صادر نمی‌کند. (حسینی، ۱۴۰۰) امید است که پژوهش حاضر در کنار برداشتن گامی جهت بهبود عملکرد پلتفرم‌های فعلی، اطمینان لازم را جهت پیاده‌سازی این پلتفرم‌ها در ایران و بهره‌مندی از مزایای آنها ایجاد کند.

۲- نوآوری پژوهش

در این مطالعه ابتدا با ارائه مدل یادگیری ماشین نوینی، سطح ریسک عدم‌پرداخت وام‌گیرندگان بر اساس میزان تأخیر در موعد بازپرداخت پیش‌بینی می‌شود و سپس به کمک هوش مصنوعی توصیف‌پذیر، پیشنهادهای جهت بهبود نتایج پیش‌بینی شده نامطلوب ارائه می‌شود. این نوآوری‌ها در ادامه توضیح داده شده است.

۲-۱- پیش‌بینی چهار کلاسه بر اساس تأخیر در بازپرداخت وام با توانایی غربال‌گری بالا

تأخیر در بازپرداخت وام رویدادی محتمل است چراکه وام‌گیرندگان ممکن است در زمان‌بندی بازپرداخت با معضلات متعددی مواجه شوند و نتوانند به آن پایبند باشند. از طرف دیگر معمولاً وام‌دهندگان سید سهام تخصصی و برنامه‌های دقیقی برای سرمایه‌گذاری‌های مختلف دارایی خود مشخص کرده‌اند به طوری که پرداخت به موقع برای آنها حائز اهمیت است و سودهای مرکب ناشی از بازپرداخت دیر هنگام هم خسارت وارد شده به آنها را نمی‌تواند جبران کند. لذا آنها این حق را دارند که بدانند آیا

1 Gonzalez

2 Milne & Parboteeah

وام‌گیرندگان به برنامه‌زمانی وام خود پایبند خواهند بود یا نمی‌توانند زمان‌بندی مشخص شده را رعایت کنند. با این حال در ادبیات به صورت صفر و یکی با این مسأله برخورد شده است و صرفاً بازپرداخت کامل یا نکول وام‌گیرندگان در این پلتفرم‌ها پیش‌بینی می‌شود. لذا این مطالعه تلاش کرده تا با در نظر گرفتن مجموع میزان تأخیر در بازپرداخت، این شکاف تحقیقاتی را پر کند.

۲-۲- در نظر گرفتن تفسیرپذیری مدل و بهبود نتایج پیش‌بینی

اخیراً بخشی از پژوهش‌ها به صورت کورکورانه صرفاً در تلاش‌اند تا با استفاده از روش‌های جعبه سیاهی همچون یادگیری عمیق و یا توسعه روش‌های کلاسیک، مدل‌های هر چه پیچیده‌تر با قدرت پیش‌بینی بالاتری را ارائه کنند؛ حال آنکه سودآوری یک کسب‌وکار در کنار داشتن مدلی قدرتمند، به توانایی تفسیر انسان از آن مدل‌ها نیز بستگی دارد. به عبارت دیگر، اگر پژوهشگران تمایل به ارائه مدلی قابل اجرا توسط صاحبان پلتفرم دارند، باید توازنی از دقت و تفسیرپذیری را به صورت توأمان داشته باشند و به یک جنبه سوگیری نکنند. مدل‌های کلاسیک یادگیری ماشین همچون رگرسیون و درخت تصمیم تفسیرپذیری بالا و قدرت پیش‌بینی کمی دارند و مدل‌های مبتنی بر یادگیری عمیق تفسیرپذیری پایین اما دقت بالایی دارند. لذا این مطالعه تلاش کرده بر خلاف سایر پژوهش‌های حوزه همتابه‌همتا، هر دو جنبه را در نظر بگیرد و در نهایت مدلی قابل اجرا در عمل پیاده کند. نهایتاً از مباحث هوش مصنوعی توصیف‌پذیر نیز در این مطالعه استفاده شده است.

۳- مرور ادبیات

در این بخش، ابتدا در جدول ۱ پژوهش‌هایی که در ارائه مدل‌های یادگیری ماشین در حوزه وام‌دهی همتابه‌همتا مشارکت داشتند مقایسه شده و سپس پژوهش‌هایی که روش حل این پژوهش از آنها الهام گرفته شده، در ادامه مرور شده است.

جدول ۱- مرور ادبیات مقایسه‌ای مدل‌های یادگیری ماشین پلتفرم‌های وام‌دهی همتابه‌همتا

ردیف	پژوهشگران مطالعه	سال	نوع	زیرنوع	توضیحات مدل
۱	بابایی و بامداد	۲۰۲۰	با نظارت	رگرسیون لجستیک و شبکه عصبی مصنوعی (ANN)	پرسپترون چند لایه (MLP ^۱)
۲	دوان	۲۰۱۹	با نظارت	شبکه عصبی عمیق (DNN ^۳)	پرسپترون چند لایه با سه لایه پنهان آموزش دیده توسط الگوریتم پس انتشار
۳	رائو و همکاران	۲۰۲۰	با نظارت	دسته‌بندی‌کننده داخلی لجستیک لاسو / دسته‌بندی‌کننده جنگل تصادفی	مدل جنگل تصادفی دو مرحله‌ای وفق دهنده حساس به هزینه
۴	وانگ	۲۰۱۸	با نظارت	امتیازدهی رفتاری	جنگل تصادفی ترکیبی جمعی پویا / چارچوب تحلیل بقای ترکیبی
۵	سانگ	۲۰۲۰	با نظارت	یادگیری چند نمایی	یادگیری جمعی چند نمایی مبتنی بر خوشه‌بندی تطبیقی فاصله تا مدل
۶	ژو	۲۰۱۹	با نظارت	یادگیری جمعی ناهمگن	یک مدل پیش‌بینی جمعی ناهمگن مبتنی بر مدل درخت تصمیم
۷	لیو و همکاران ^I	۲۰۲۱	با نظارت	مدل رگرسیون لجستیک	المان‌سازی خوشه‌بندی ^۴ یا گسسته‌سازی یکنواخت ^۵
۸	لیو و همکاران ^{II}	۲۰۲۱	با نظارت	مدل رگرسیون لجستیک	آزمون t وابسته برای نمونه‌های زوجی
۹	گوا و همکاران	۲۰۱۶	با نظارت	مدل رگرسیون لجستیک	رگرسیون هسته‌ای / روش اعتبارسنجی متقاطع یک طرفه حداقل مربعات
۱۰	شیا، لیو و لیو	۲۰۱۷	با نظارت	درخت رگرسیون	یادگیری حساس به هزینه و افزایش شدید گرادیان (XGBoost ^۶) / آزمون t زوجی

- 1 Artificial Neural Network
- 2 Multi-Layer Perceptron
- 3 Deep Neural Network
- 4 clustering discretization
- 5 uniform quantization
- 6 Extreme Gradient Boosting

نیو^۱ و همکاران (۲۰۲۰) یک مدل جمعی نمونه‌گیری جدید مبتنی بر توزیع داده‌ها برای ارزیابی ریسک اعتباری داده‌های نامتعادل در وام‌دهی همتابه‌همتا پیشنهاد کردند. این مدل مشکل عدم تعادل را با استفاده از روش کم‌نمونه‌گیری پیشنهادی بر اساس توزیع داده‌های کلاس اکثریت حل می‌کند. با این کار، از دست دادن اطلاعات کلاس اکثریت تا حد زیادی کاهش می‌یابد.

زی^۲ و همکاران (۲۰۰۹) یک الگوریتم ادغام مبتنی بر جنگل‌های تصادفی متعادل و جنگل‌های تصادفی وزن‌دار برای مدیریت دسته‌بندی داده‌های نامتعادل پیشنهاد کردند. الگوریتم آنها از شیوه‌های حساس به هزینه و نمونه‌گیری برای متعادل کردن داده‌ها استفاده می‌کند. نتایج تجربی روی پایگاه‌های داده بانکی نشان داده است که روش آنها دقت بالاتری نسبت به سایر الگوریتم‌های جنگل‌های تصادفی ایجاد می‌کند.

وانگ^۳ و همکاران (۲۰۱۸) یک مدل امتیازدهی رفتاری جدید به نام جنگل تصادفی ترکیبی پویا مبتنی بر چارچوب تجزیه و تحلیل بقا را پیشنهاد کردند که برای پیش‌بینی احتمال پویایی عدم پرداخت در طول زمان در وام‌دهی همتابه‌همتا است. آنها در پژوهش خود مؤلفه‌های وقوع و تأخیر را با استفاده از روش‌های مبتنی بر درخت و همچنین روش یادگیری جمعی مدل‌سازی کردند که می‌تواند با رابطه غیرخطی بالقوه بین متغیرهای مستقل و متغیر هدف مقابله کند و به بهبود عملکرد کمک کند.

مطالعه فرناندز لوریا، پرووست و هان^۴ (۲۰۲۰) توضیحات خلاف‌واقع^۵ را با روش‌های توضیح‌دهنده پیش‌بینی مدل با توجه به اهمیت ویژگی‌ها مقایسه می‌کند (به عنوان مثال SHAP, LIME) و چرایی تصمیم‌گیری در خصوص اهمیت توضیحات برای تبیین تصمیمات سیستم را بررسی می‌کند. به عبارت دیگر نویسندگان نشان می‌دهند که (۱) ویژگی‌هایی که دارای اهمیت (وزن) زیادی برای پیش‌بینی مدل هستند، ممکن است بر تصمیم مربوطه تأثیر نگذارد و (۲) وزن‌های مهم برای بیان اینکه چطور و چگونه ویژگی‌ها بر تصمیمات تأثیر می‌گذارد، کافی نیستند.

در مطالعه موتیلال، شارما و تان^۶ (۲۰۲۰) چارچوبی برای ایجاد و ارزیابی مجموعه متنوعی از توضیحات خلاف‌واقع (DiCE^۷) بر اساس فرایندهای نقطه تعیین‌کننده پیشنهاد می‌شود. برای ارزیابی قابلیت اجرای موارد خلاف‌واقع، نویسندگان معیارهایی را ارائه می‌دهند که امکان مقایسه روش‌های مبتنی بر خلاف‌واقع را با سایر روش‌های توضیح محلی فراهم می‌کند. آنها در ادامه به مبادلات لازم می‌پردازند و پیامدهای علی در بهینه‌سازی برای موارد خلاف‌واقع اشاره می‌کنند.

۴- روش پژوهشی

روش پژوهشی این مطالعه و اینکه چه ورودی‌هایی در خلال چه گام‌هایی به خروجی تبدیل می‌شوند، در فلوجارت شکل ۱ آورده شده است. طبق این فلوجارت ابتدا می‌بایست به منظور جمع‌آوری داده‌های خام، پلتفرم‌های موجود بررسی شود و نهایتاً پلتفرم معتبری با حجم معاملات و گردش مالی بالا انتخاب شود که حاوی اطلاعات وام‌گیرندگان و درخواست وام باشد. در این مطالعه از مجموعه داده‌های پلتفرم لندینگ کلاب^۸ استفاده شده که شامل ۸۸۷,۳۷۹ سطر و ۷۴ ستون بوده و مربوط به سال ۲۰۰۷ تا ۲۰۱۸ می‌باشد. این مجموعه داده به عنوان ورودی مدل‌های یادگیری استفاده می‌شود. ستون‌های این مجموعه داده را می‌توان به سه بخش تقسیم کرد: (۱) مشخصات وام‌گیرنده مانند سابقه شغلی، سن، وضعیت تأهل، تحصیلات، درآمد و وضعیت مالکیت خانه / (۲) مشخصات وام مانند رتبه اعتباری، مبلغ، مدت و هدف / (۳) کارایی وام مانند اطلاعاتی در مورد بازپرداخت وام، فرآیند جمع‌آوری یا برنامه‌زمانی وام.

پیش از ساخت مدل‌های یادگیری، می‌بایست پیش‌پردازش‌هایی روی داده‌های خام انجام شود. به همین منظور، ابتدا باید نوع داده تخصیص داده‌شده به ویژگی‌ها بررسی و تبدیلات لازم در صورت نیاز اعمال شود. سپس به کمک روش‌های آمار توصیفی و تحلیل اکتشافی، وضعیت آماری ویژگی‌ها و پراکندگی آنها مورد بررسی قرار گیرد تا شناخت بهتری نسبت به آنها به دست آید. پس از آن ستون‌ها یا سطرهای با مقادیر گم‌شده بیش از ۵۰٪ حذف و مقادیر باقی‌مانده به کمک رگرسیون خطی یا مقدار none جایگزاری شوند. سپس داده‌های نویزدار و پرت حول میانگین جایگزین و مقادیر با فاصله زیاد حذف شوند. همچنین توزیع آماری و رفتاری ویژگی‌های کمی و کیفی می‌بایست به تفکیک وضعیت‌های مختلف متغیر هدف مورد بررسی قرار گیرند. آنگاه به کمک تفسیر مقادیر و علامت‌های مثبت یا منفی ویژگی‌ها در ماتریس همبستگی و ضرایب معنی‌داری آزمون t در رگرسیون لجستیک از یک طرف و دانش مربوط به سیاست‌های مدیریت پلتفرم و مباحث اقتصادی از طرف دیگر، همراستایی‌های چندانگانه در صورت

1 Niu

2 Xie

3 Wang

4 Fernández-Loría, Provost & Han

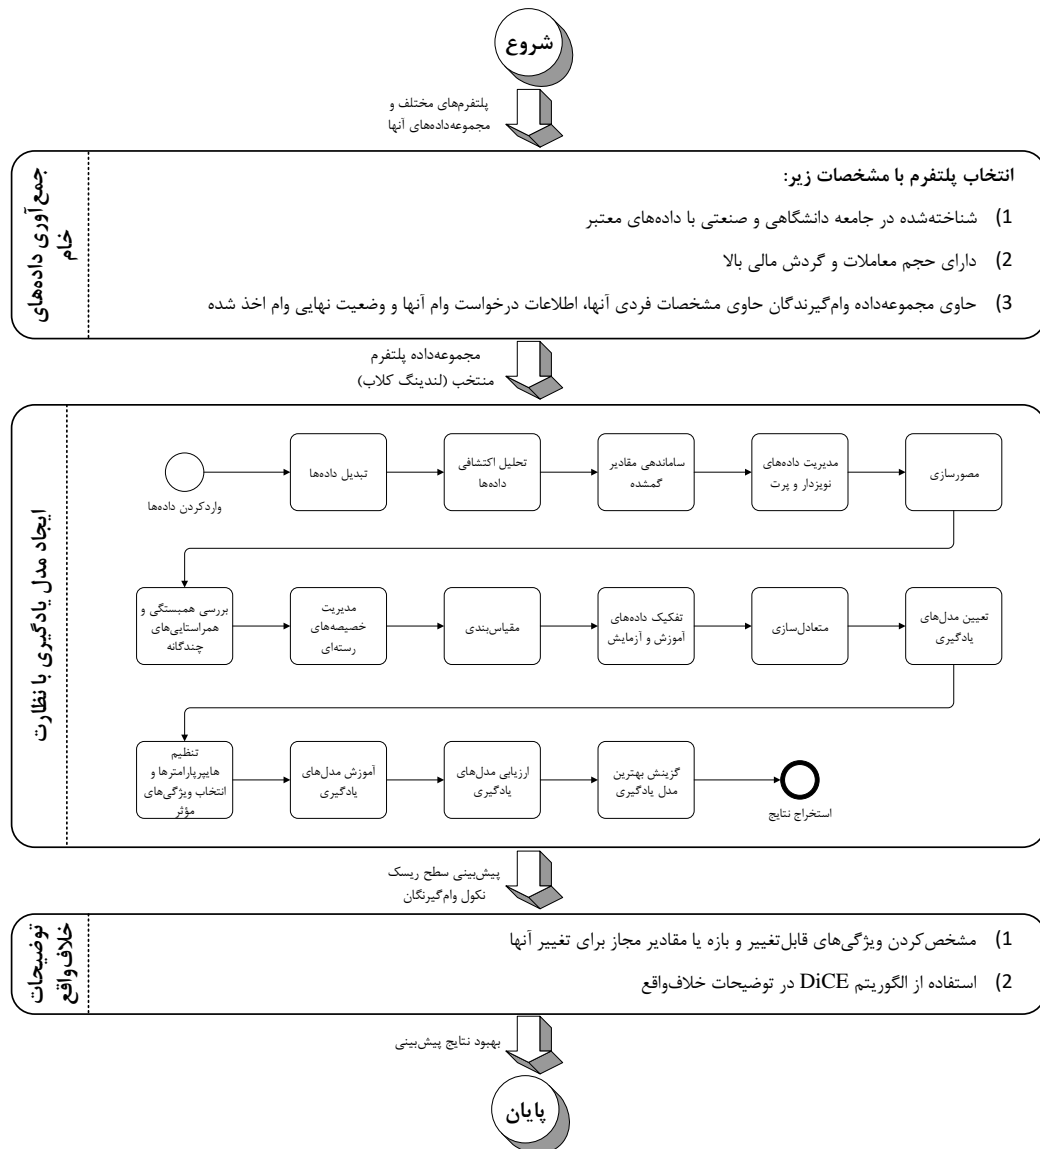
5 counterfactual explanation

6 Mothilal, Sharma, & Tan

7 Diverse Counterfactual Explanations

8 LendingClub

وجود شناسایی شوند. سپس ویژگی‌های رشته‌ای به کمک روش‌هایی همچون ایجاد متغیرهای مصنوعی دودویی به ویژگی‌های عددی تبدیل شوند. آنگاه نیاز است مقیاس داده‌ها با روش‌هایی همچون مقیاس‌بندی استاندارد اصلاح شود. پس از انجام پیش‌پردازش‌های بیان‌شده، نیاز است داده‌ها به دو قسمت آموزش و آزمایش تقسیم شوند. سپس با توجه به اینکه داده‌های بازپرداخت وام عموماً نامتعادل هستند، می‌بایست از روش‌های نمونه‌گیری یا وزن‌دهی برای متعادل‌سازی مجموعه داده آموزش استفاده کرد. پس از آن می‌بایست مدل‌های غیر جعبه سیاه یادگیری کلاسیک و مبتنی بر درخت با توجه به تجربه‌های موفق گذشته و از دست ندادن تفسیرپذیری انتخاب شوند. آنگاه به منظور تعیین هایپرپارامترهای بهینه و انتخاب ویژگی‌های تأثیرگذار در آموزش مدل، می‌توان از تلفیق روش‌های جست‌وجوی شبکه توری و اعتبارسنجی متقابل استفاده کرد. سپس باید مدل‌ها را با معیارهای غربال‌گری ادبیات موضوع ارزیابی کرد و مدل با بهترین عملکرد را انتخاب کرد. نهایتاً با مشخص کردن ویژگی‌های قابل تغییر و سپس بازه یا مقادیر مجاز تغییرات آنها، از توضیحات خلاف واقع برای بهبود نتایج استفاده کرد.



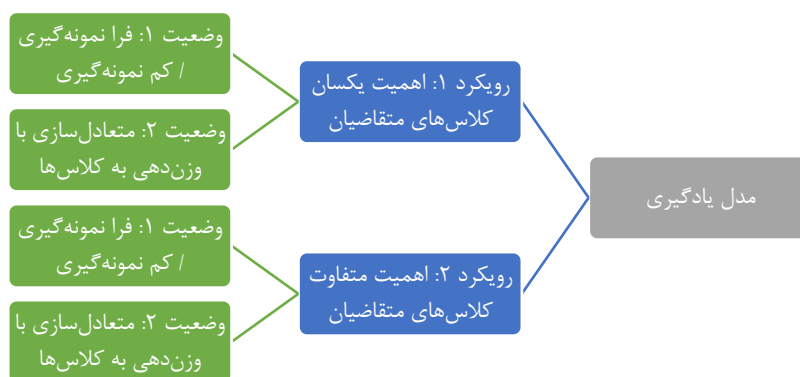
شکل ۱- قدم‌های ساخت و بهبود نتایج مدل یادگیری

لازم به ذکر است زبان برنامه‌نویسی اصلی استفاده شده، زبان پایتون نسخه 3.9 می‌باشد چرا که بسیار انعطاف‌پذیر و محبوب است و همچنین به دلیل کتابخانه‌های متعدد و کاربران زیاد برای پیاده‌سازی مدل‌های یادگیری مناسب می‌باشد. همچنین سیستم عامل استفاده شده برای کدزنی ویندوز ۱۰ نسخه ۶۴ بیتی با رم ۸ گیگابایت و پردازنده 1.80 گیگاهرتز با چهار هسته می‌باشد. البته برای تعیین هایپرپارامترها نیاز که به پردازش طولانی‌تری بود از نسخه رایگان محیط Colab استفاده شده است.

۵- پیاده‌سازی روش پژوهشی

برای ساخت مدل یادگیری و بهبود نتایج نامطلوب آن، گام‌های فلوجارت تشریح شده در بخش قبل طی می‌شود اما ابتدا نیاز است نحوه‌ی متعادل‌سازی مجموعه داده توضیح داده شود. به طور کلی این پلتفرم‌ها نرخ نکول بالاتری نسبت به وام‌های بانکی دارند که در واقعیت مطلوب نیست ولی پیش‌بینی دقیق‌تری را ارائه می‌کند.

در این مطالعه برای غلبه بر مسأله داده‌های نامتعادل، از روش‌های مربوط به پیش از یادگیری مدل استفاده می‌شود و روش‌های پس از یادگیری در مرحله ارزیابی مدل مورد استفاده قرار می‌گیرند. مدل‌ها در دو رویکرد و هر رویکرد در دو وضعیت (مجموعاً چهار حالت) آموزش می‌بینند. رویکردها مربوط به اهمیت متقاضیان و وضعیت‌ها مربوط به غلبه بر مشکل عدم تعادل کلاس‌ها می‌باشند. در رویکرد اول متقاضیان نسبت به هم برتری ندارند ولی در رویکرد دوم متقاضیان اهمیت متفاوتی نسبت به یکدیگر دارند؛ متقاضیانی که نکول کرده‌اند دارای بالاترین اهمیت، بعد متقاضیان با ۳۱ الی ۱۲۰ روز تأخیر در بازپرداخت در جایگاه دوم، سپس متقاضیان با ۱ الی ۳۰ روز تأخیر در جایگاه سوم و نهایتاً کمترین اهمیت مربوط به متقاضیانی که سر موعد پرداخت‌های خود را انجام داده‌اند می‌باشد. در وضعیت اول از روش‌های کم/فرا نمونه‌گیری یا تولید نمونه‌های مصنوعی همچون SMOTE استفاده می‌شود و در وضعیت دوم از وزن‌دهی به کلاس‌ها به منظور تکرار کلاس‌های اقلیت استفاده می‌شود. نهایتاً چهار حالت مطابق با شکل ۲ ایجاد می‌شود.



شکل ۲- حالت‌های متعادل‌سازی کلاس‌ها

۵-۱- ایجاد مدل‌های یادگیری

در ادبیات این حوزه مسائل به صورت یادگیری با نظارت دو کلاس (بازپرداخت کامل / نکول) مدل شده‌اند و به میزان پایبندی به برنامه‌زمانی تعیین شده برای بازپرداخت توجهی نشده است در حالی که تأخیر در بازپرداخت، عاملی محتمل است و در نظر نگرفتن آن نقص مهمی به حساب می‌آید. لذا در این مطالعه، دسته‌بندی بر اساس مجموع تأخیر در بازپرداخت وام‌گیرندگان ارائه شده است. برای اعمال این موضوع دو راه‌کار وجود دارد: راه‌کار اول این است که مسأله به صورت پیوسته مدل شود و مجموع تعداد روز تأخیر در بازپرداخت پیش‌بینی شود. اما این راه‌کار از نظر عوامل انسانی و محاسباتی توجیه‌پذیر نیست چرا که:


- ۱) مدلی خاص با دقت تشخیص پایینی برای پیش‌بینی آینده به دست خواهد آمد چرا که تنوع رفتار وام‌گیرندگان نسبت به میزان تأخیر آنها بالاست و الگوهای بسیار متعددی وجود دارد.
- ۲) اعداد نزدیک به هم از نظر معنی‌داری برای وام‌دهندگان یکسان می‌باشند؛ اینکه فردی مجموعاً ۵ یا ۶ روز در پرداخت‌های خود تأخیر خواهد داشت برای وام‌دهندگان آنچنان ارزشی ندارد که مدل بر اساس آن آموزش ببیند.
- ۳) همچنین این نوع خروجی عددی در ذهن انسان به صورت مستقیم تفسیرپذیر نیست و ذهن به صورت خودآگاه یا ناخودآگاه نتیجه را دسته‌بندی کرده و سپس در خصوص تأمین مالی تصمیم‌گیری می‌کند. لذا بهتر است این دسته‌بندی بر اساس نظر متخصصان و سیاست‌های داخل خود پلتفرم تعیین شود تا نهایتاً پیش‌بینی با دقت بالاتری به وام‌دهندگان عرضه شود.

لذا در این مطالعه از راه‌کار دوم استفاده خواهیم کرد و مسأله را به صورت گسسته حل می‌کنیم که نیاز است مدلی چند کلاس ساخته شود. تصمیم‌گیری در خصوص تعداد کلاس‌ها به عوامل مختلفی بستگی دارد و خود می‌تواند یک مسأله بهینه‌سازی مجزا باشد اما در اینجا از سیاست‌های پلتفرم لندینگ کلاب ایده گرفته شده است. در این پلتفرم وام‌هایی که هنوز باز هستند به سه دسته تقسیم می‌شوند: ۱ الی ۱۵ روز تأخیر (دوره تنفس)، ۱۶ الی ۳۰ روز تأخیر و ۳۱ الی ۱۲۰ روز تأخیر. با توجه به اینکه تمایز دو دسته اول تعلق یا عدم تعلق جریمه دیرکرد می‌باشد و در اینجا جریمه اهمیتی ندارد، نهایتاً چهار دسته برای وضعیت وام‌های بسته‌شده

متصور می‌شود؛ پرداخت بدون تأخیر (کلاس صفر)، پرداخت با ۱ الی ۳۰ روز تأخیر (کلاس سه)، پرداخت با ۳۱ الی ۱۲۰ روز تأخیر (کلاس دو) و عدم پرداخت (کلاس یک).

۲-۵- ارزیابی مدل‌های یادگیری

برای ارزیابی عملکرد مدل‌های آموزش داده شده و انتخاب بهترین مدل، به هر کلاس وزنی تخصیص داده شده و سپس ماتریس هزینه تعریف می‌شود. این وزن‌ها با توجه به سیاست‌ها و اهداف مختلف هر پلتفرم می‌توانند متفاوت باشند. در این مطالعه به کمک معیارهای توضیح داده شده در مطالعه گراندینی، باگلی و ویسانی^۱ (۲۰۲۰) از ۵ معیار برای بررسی عملکرد استفاده شده است. در ادامه محاسبات این معیارها برای مدل جنگل تصادفی با رویکرد عدم برتری متقاضیان نسبت به یکدیگر و وضعیت فرا/کم نمونه‌گیری که دارای بهترین عملکرد بوده، محاسبه خواهد شد. با این پیش فرض که اهمیت کلاس اول ۹ برابر کلاس صفر، کلاس دوم ۷ برابر کلاس صفر و کلاس سوم ۳ برابر کلاس صفر می‌باشد، وزن هر کلاس در جدول ۲ مشخص شده است. همچنین ماتریس هزینه و ماتریس درهم‌ریختگی جنگل تصادفی به ترتیب در شکل‌های ۳ و ۴ نشان داده شده است.



شکل ۴- ماتریس درهم‌ریختگی جنگل تصادفی

شکل ۳- ماتریس هزینه

جدول ۲- وزن هر کلاس

کلاس	پرداخت بدون تأخیر (صفر)	عدم پرداخت (یک)	پرداخت با ۳۱ الی ۱۲۰ روز تأخیر (دو)	پرداخت با ۱ الی ۳۰ روز تأخیر (سه)
وزن	0.05	0.45	0.35	0.15

با توجه به نتایج شاخص‌های تعریف شده در جدول ۳، مدل‌های جنگل تصادفی، Gradient Boosting و XGBoost عملکرد خوب و نزدیکی دارند. با این حال به دلیل برتری جنگل تصادفی در معیارهای صحت و دقت وزن دار و همچنین تفسیرپذیری بالاتر، آن را به عنوان بهترین مدل انتخاب می‌کنیم. با فرض برابری اهمیت متقاضیان، در ادامه سایر توضیحات و محاسبات بر اساس رویکرد اول ارائه خواهد شد.

جدول ۳- ارزیابی مدل‌های آموزش داده شده

ردیف	مدل	رویکرد	وضعیت	صحت	دقت وزن دار	سطح زیر منحنی مشخصه عملکرد سیستم	ضریب همبستگی ماتریس	هزینه کل مقیاس شده
۱	Logistic Regression	اهمیت یکسان کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.60	0.70	0.73	0.47	63,454
			متعادل سازی با وزن دهی به کلاس‌ها	0.80	0.56	0.76	0.51	50,909
		اهمیت متفاوت کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.57	0.52	0.71	0.45	69,096
			متعادل سازی با وزن دهی به کلاس‌ها	0.77	0.32	0.73	0.52	61,415

1 Grandini, Bagli & Visani

ردیف	مدل	رویکرد	وضعیت	صحت	دقت وزن دار	سطح زیر منحنی مشخصه عملکرد سیستم	ضریب همبستگی ماتریوس	هزینه کل مقیاس شده
۲	Naive Bayes	اهمیت یکسان کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.57	0.68	0.71	0.48	65,829
			متعادل سازی با وزن دهی به کلاس‌ها	-	-	-	-	-
		اهمیت متفاوت کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.56	0.67	0.71	0.49	66,417
			متعادل سازی با وزن دهی به کلاس‌ها	-	-	-	-	-
۳	Decision Tree	اهمیت یکسان کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.85	0.82	0.90	0.81	31,555
			متعادل سازی با وزن دهی به کلاس‌ها	0.85	0.48	0.73	0.62	41,189
		اهمیت متفاوت کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.85	0.82	0.90	0.80	31,777
			متعادل سازی با وزن دهی به کلاس‌ها	0.85	0.48	0.73	0.62	41,487
۴	Random Forest	اهمیت یکسان کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.91	0.90	0.94	0.87	24,854
			متعادل سازی با وزن دهی به کلاس‌ها	0.88	0.57	0.69	0.66	41,370
		اهمیت متفاوت کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.91	0.90	0.94	0.88	24,715
			متعادل سازی با وزن دهی به کلاس‌ها	0.87	0.56	0.68	0.65	42,657
۵	XGBoost Classifier	اهمیت یکسان کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.90	0.90	0.94	0.88	22,028
			متعادل سازی با وزن دهی به کلاس‌ها	-	-	-	-	-
		اهمیت متفاوت کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.90	0.88	0.94	0.88	19,980
			متعادل سازی با وزن دهی به کلاس‌ها	-	-	-	-	-
۶	AdaBoost Classifier	اهمیت یکسان کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.64	0.64	0.76	0.53	64,420
			متعادل سازی با وزن دهی به کلاس‌ها	-	-	-	-	-
		اهمیت متفاوت کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.60	0.53	0.73	0.49	66,495
			متعادل سازی با وزن دهی به کلاس‌ها	-	-	-	-	-
۷	Gradient Boosting Classifier	اهمیت یکسان کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.90	0.90	0.93	0.87	24,779
			متعادل سازی با وزن دهی به کلاس‌ها	-	-	-	-	-
		اهمیت متفاوت کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.90	0.89	0.93	0.87	23,612
			متعادل سازی با وزن دهی به کلاس‌ها	-	-	-	-	-

۵-۳- محاسبات معیارهای جنگل تصادفی

به منظور نماد گذاری، در نظر بگیرید T نشان دهنده مجموعه داده آزمایش حاوی n سطر (نمونه) و K کلاس (برچسب) باشد و وزن کلاس k ام به ازای $1 \leq k \leq K$ را با w_k درایه سطر i ام و ستون j ام ماتریس هزینه را با C_{ij} اندیس کلاس واقعی نمونه‌ها را با KA، اندیس کلاس پیش‌بینی شده نمونه‌ها را با KP و رویداد تشخیص را با E_{KA}^{KP} نشان دهیم به نحوی که اگر تشخیص صحیح باشد $KA = KP$ و اگر تشخیص کاذب باشد $KA \neq KP$ خواهد بود.

(۱) معیار صحت: این معیار بیشترین کاربرد را دارد و نشان دهنده نسبت برچسب‌های صحیح پیش‌بینی شده یک کلاس به تعداد کل برچسب‌های موجود می‌باشد.

$$Accuracy (A) = \frac{\sum_{KA} E_{KA}^{KA}}{\sum_{KA} \sum_{KP} E_{KA}^{KP}} \quad (۱) \quad A = \frac{40529 + 32788 + 38482 + 38650}{166171} = 0.9054$$

(۲) معیار دقت وزن دار: این معیار نشان دهنده نسبت برچسب‌های صحیح پیش‌بینی شده یک کلاس به تعداد کل برچسب‌های واقعی آن کلاس است.

$$Weighted Precision (WP) = \sum_k W_k \times precision \text{ of class } k = \sum_{KP} W_{KP} \frac{E_{KP}^{KP}}{\sum_{KA} E_{KA}^{KP}} \quad (۲)$$

$$WP = 0.05 \times \frac{40529}{43914} + 0.45 \times \frac{32788}{35170} + 0.35 \times \frac{38482}{44371} + 0.15 \times \frac{38650}{42716} = 0.9049$$

(۳) معیار ضریب همبستگی ماتیوس ۱: این ضریب به طور کلی به عنوان یک معیار متعادل شده می‌باشد به طوری که برای داده‌های نامتعادل نیز دارای عملکرد مناسبی می‌باشد.

$$t_k = t^{KA} = \sum_{KP} E_{KA}^{KP} \quad (۳) \quad p_k = p^{KP} = \sum_{KA} E_{KA}^{KP} \quad (۴) \quad c = \sum_{KA} E_{KA}^{KA} \quad (۵) \quad s = \sum_{KA} \sum_{KP} E_{KA}^{KP} \quad (۶)$$

$$MCC = \frac{c \times s - \sum_k p_k \times t_k}{\sqrt{(s^2 - \sum_k p_k^2) \times (s^2 - \sum_k t_k^2)}} \quad (۷)$$

$$MCC = \frac{(40529 + 32788 + 38482 + 38650) \times 166171 - (43914 \times 41386 + \dots)}{\sqrt{(166171^2 - (43914^2 + \dots)) \times (166171^2 - (41386^2 + \dots))}} = 0.8751$$

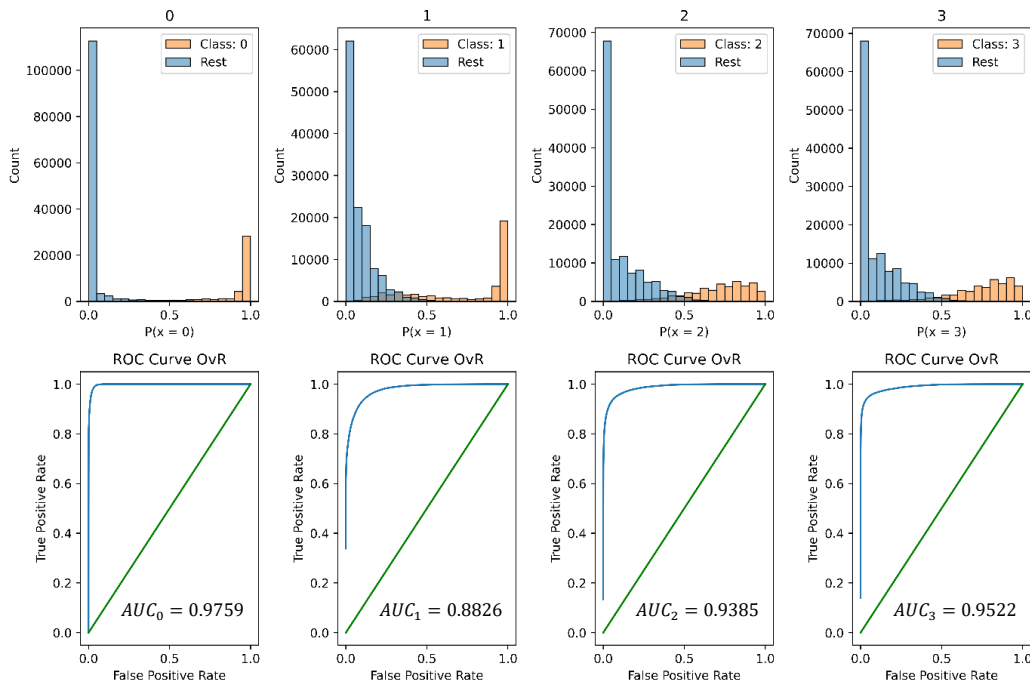
(۴) معیار هزینه کل مقیاس شده: در این معیار درایه‌های ماتریس درهم‌ریختگی به صورت نظیر به نظیر در درایه‌های ماتریس هزینه ضرب شده و هزینه کل پیش‌بینی محاسبه می‌شود.

$$total \ scaled \ cost = \frac{support \ weighing}{support \ sampling} \times \sum_i \sum_j C_{ij} \times E_i^j \quad (۸) \quad \text{وضعیت فرا/کم نمونه‌گیری}$$

$$total \ scaled \ cost = \frac{support \ weighing}{support \ weighing} \times \sum_i \sum_j C_{ij} \times E_i^j \quad (۹) \quad \text{وضعیت وزن دهی به کلاس‌ها}$$

$$total \ scaled \ cost = \frac{54876}{166171} \times (40529 \times 0 + 666 \times 6 + 133 \times 4 + 58 \times 1 + \dots) = 24,854$$

(۵) معیار سطح زیر منحنی مشخصه عملکرد سیستم: منحنی مشخصه عملکرد یا منحنی عملیاتی دریافت کننده، نموداری از جنس احتمال است که عملکرد یک مدل دسته‌بندی را به ازای آستانه‌های مختلف نشان می‌دهد. در اینجا از روش «یک در مقابل بقیه» و نهایتاً میانگین‌گیری از کلاس‌ها استفاده شده است. توزیع‌های هر کلاس نسبت به بقیه و منحنی‌های مشخصه عملکرد برای مدل جنگل تصادفی در شکل ۵ نشان داده شده است.



شکل ۵- توزیع‌های هر کلاس نسبت به بقیه و منحنی‌های مشخصه عملکرد برای مدل جنگل تصادفی

۵-۳- توضیحات خلاف‌واقع

پیش‌بینی رویدادهای آینده که به کمک قدم‌های قبل محقق می‌شود، بسیار ارزشمند است اما کافی نیست. ما یک قدم فراتر می‌رویم و تلاش می‌کنیم آینده را به نحوی که تمایل داریم محقق سازیم. توضیحات خلاف‌واقع این امکان را برای وام‌گیرندگان فراهم می‌کند تا بتوانند رتبه اعتباری خود را بهبود دهند و با احتمال بیشتری وام‌های با شرایط بهتر دریافت کنند. توضیحات خلاف‌واقع روابط علی میان پدیده‌ها را توصیف می‌کنند و برای تغییر نتایج به دست آمده به کار می‌روند. به عبارت دیگر اگر نتیجه حاصل شده باشد، توضیحات خلاف‌واقع به دنبال رویدادی همچون X هستند که اگر رخ نمی‌داد، نتیجه Y حاصل نمی‌شد. لذا استفاده از این مفهوم مستلزم تصور واقعیتی فرضی است که با واقعیت‌های مشاهده‌شده در تضاد هست. برای همین از اصطلاح خلاف‌واقع استفاده شده است. برای تغییر یک نتیجه و توضیح شرایطی خلاف‌واقع، می‌بایست مسبب‌های آن شناسایی شوند. واضح است که هر چه مدل آموزش دیده ساده‌تر و تأثیرات متغیرهای ورودی روی متغیر خروجی واضح‌تر باشد، ساده‌تر می‌توان نتیجه را تغییر داد. البته در مسائل ابعاد بزرگ حتی مدل‌های ساده می‌توانند غیرقابل تفسیر باشند؛ مثلاً نمی‌توان به سادگی تأثیرات متغیرهای ورودی بر نتیجه نهایی را در مدل رگرسیونی که ۵۰ متغیر ورودی دارد شناسایی کرد. البته تمامی معضلات به همینجا ختم نمی‌شود. اعمال تغییر در دنیای واقعی ممکن است بسیار هزینه‌بر و یا غیرممکن باشد. مثلاً نمی‌توان سن را کاهش داد یا نمی‌توان اتفاقاتی که در گذشته برای افراد رخ داده را از بین برد. لذا ما به سناریویی علاقه‌مند هستیم که دارای کمینه هزینه باشد. در این مطالعه از توضیحات خلاف‌واقع DiCE استفاده شده است. این نوع توضیح می‌گوید وام‌گیرنده مورد نظر چه تغییراتی می‌تواند انجام دهد تا نتیجه پیش‌بینی اعلام شده به او تغییر کند. به این منظور، ابتدا سه عامل باید تعیین شود که در ادامه بیان شده است.

- (۱) ویژگی‌هایی که تغییر آنها امکان‌پذیر است می‌بایست مشخص شوند.
 - (۲) برای ویژگی‌هایی عددی قابل تغییر، بازه مجاز برای تغییر می‌بایست مشخص شود.
 - (۳) برای ویژگی‌های رسته‌ای قابل تغییر، مقادیر مجاز برای تغییر می‌بایست مشخص شود.
- در جداول ۴ و ۵ نمونه توضیحات خلاف‌واقع برای دسته‌بندی در کلاس صفر آورده شده است. در سطر اول این جدول برخی از اطلاعات واقعی فرد و در سطرها بعد، پیشنهادات به او برای تغییر نتیجه پیش‌بینی نشان داده شده است.

جدول ۴- نمونه توضیحات خلاف‌واقع برای تغییر از کلاس یک به صفر

نتیجه وام	هدف وام	نوع استخدام	درآمد سالانه	
Default	car	other	30000	original
no lateness	small_business	other	2134819	1
no lateness	credit_card	other	1511225	2

جدول ۵- نمونه توضیحات خلاف‌واقع برای تغییر از کلاس دو به صفر

نتیجه وام	وضعیت تایید درآمد یا منبع درآمد	وضعیت مالکیت خانه	درآمد سالانه	
Late (31-120 days)	Source Verified	MORTGAGE	50000	original
no lateness	Source Verified	OWN	50000	1
no lateness	Verified	MORTGAGE	50000	2

۶- صحت‌سنجی

در اینجا به سه صورت مدل یادگیری ارائه شده مورد صحت‌سنجی قرار می‌گیرد.

۶-۱- برتری نسبت به عملکرد فعلی پلتفرم

با ورود متقاضیان به پلتفرم امتیازی به آنها تخصیص می‌یابد و ریسک عدم‌پرداخت آنها ارزیابی می‌شود. اگر بخواهیم صرفاً به امتیازدهی پلتفرم اعتماد کنیم و دسته‌بندی را بر مبنای آن انجام دهیم، نتیجه مطابق جدول ۶ به دست می‌آید. همانطور که مشخص است، نتیجه به دست آمده در این مطالعه قدرت تشخیص بسیار بالاتری نسبت به گروه‌بندی خود پلتفرم در سیاست چهار کلاس از خود نشان می‌دهد.

جدول ۶- عملکرد پیش‌بینی چهار کلاس بر اساس امتیاز اعتباری پلتفرم

مدل	صحت	دقت وزن‌دار	سطح زیر منحنی مشخصه عملکرد سیستم	ضریب همبستگی ماتریوس	هزینه کل مقیاس‌شده
امتیازدهی پلتفرم	0.43	0.22	0.56	0.12	571,901

۶-۲- برتری نسبت به پیش‌بینی‌کننده دو کلاس: هزینه کمتر

اگر مسأله را به همان شیوه دو کلاس که در ادبیات وجود دارد در نظر بگیریم به صورتی که وام‌گیرنده یا وام را به صورت کامل بازپرداخت می‌کند یا نکول می‌کند، چون تعداد کلاس‌ها و پراکندگی کمتر می‌شود، دقت مدل افزایش خواهد یافت اما هزینه‌های سنگین‌تری در صورت پیش‌بینی اشتباه تحمیل خواهد شد. در اینجا اگر هزینه‌های حالت چهار کلاس در دو کلاس تجمیع شود، هزینه کل بیشتر از حالت چهار کلاس خواهد شد و لذا مسأله چهار کلاس برتری خواهد یافت. نتایج حالت دو کلاس در جدول ۷ آورده شده است.

جدول ۷- عملکرد پیش‌بینی‌کننده دو کلاس این مطالعه

مدل	رویکرد	وضعیت	صحت	دقت وزن‌دار	سطح زیر منحنی مشخصه عملکرد سیستم	ضریب همبستگی ماتریوس	هزینه کل مقیاس‌شده
جنگل تصادفی	اهمیت یکسان کلاس‌های متقاضیان	فرا نمونه‌گیری / کم نمونه‌گیری	0.95	0.98	0.95	0.91	45,648

۶-۳- برتری نسبت به پژوهش‌های فعلی در ادبیات

با توجه به اینکه پژوهش‌هایی در ادبیات وجود دارند که از مجموعه‌داده پلتفرم لندینگ کلاب استفاده کرده‌اند و لذا ماهیت نزدیکی با مجموعه‌داده مطالعه موردی این مطالعه دارند، می‌توان حالت بدون وزن و دو کلاس روش پیشنهادی در این مطالعه را با بهترین مدل آنها مقایسه کرد. نتیجه این مقایسه در جدول ۸ آورده شده است. همانطور که مشاهده می‌شود، این مطالعه در تمامی معیارهای غربال‌گری نتایج بهتری را از خود نشان داده است.

جدول ۸- مقایسه مدل یادگیری دو کلاس با سایر مدل‌های موجود در ادبیات

ردیف	مطالعه	صحت	دقت	سطح زیر منحنی مشخصه عملکرد سیستم	ضریب همبستگی ماتریوس
۰	مطالعه فعلی	0.95	0.96	0.95	0.91
۱	ویکتور (۲۰۲۱)	0.92	0.79	0.89	0.77
۲	ها و همکاران (۲۰۱۹)	0.81	---	---	---

ردیف	مطالعه	صحت	دقت	سطح زیر منحنی مشخصه عملکرد سیستم	ضریب همبستگی ماتیوس
۳	آیاتولا (۲۰۲۰)	0.87	0.81	0.87	---
۴	ماجومدر و کیم (۲۰۲۱)	0.84	---	0.56	---
۵	ویژناندز (۲۰۲۱)	0.69	---	0.62	0.21
۶	لی و همکاران (۲۰۲۰)	0.94	---	0.95	---
۷	موسکاتو، پیکاریلو و اسپرلو ^۱ (۲۰۲۱)	0.72	---	0.64	---
۸	ناموار و همکاران (۲۰۱۸)	0.69	---	0.69	---
۹	سانگ و همکاران (۲۰۲۰)	0.72	---	0.67	---

۷- نتیجه‌گیری، جمع‌بندی و پژوهش‌های آتی

در این مطالعه روشی برای پیش‌بینی ریسک اعتبار از طریق دسته‌بندی میزان تأخیر در بازپرداخت وام در پلتفرم‌های وام‌دهی همتابه‌همتا ارائه شده به نحوی که امکان تفسیرپذیری برای پیاده‌سازی آن در واقعیت نیز در نظر گرفته شده است. مقایسه‌های انجام‌شده در این مطالعه نشان می‌دهد که روش پژوهشی حاضر در کنار قابلیت تفسیرپذیری و تلاش برای بهبود نتایج پیش‌بینی، قدرت غربال‌گری بالایی هم نسبت به پژوهش‌های موجود در ادبیات و هم نسبت به عملکرد خود پلتفرم داشته است. این پژوهش با هدف کمک به صاحبان پلتفرم با تمرکز بر افزایش رضایت و سرمایه‌وام‌دهندگان به صورت مستقیم انجام شده است که همزمان رضایت وام‌گیرندگان را نیز افزایش خواهد داد. مسیرهایی در ادامه این پژوهش می‌توان پیمود به شرح زیر می‌باشد:

- ۱) می‌توان روش پیشنهادی در این مطالعه را بر روی مطالعات موردی و مجموعه داده‌های سایر پلتفرم‌ها به کار برد و نتایج آنها را با نتایج فعلی مقایسه کرد.
- ۲) در این مطالعه مدل‌های دسته‌بندی‌کننده چهار کلاسه مورد بررسی قرار گرفتند. در پژوهش‌های آتی می‌توان با بررسی عوامل اجتماعی یا تحلیل حساسیت‌های مختلف، تعداد دسته مناسب با توجه به سیاست‌های هر پلتفرم را تعیین کرد و حتی رویکرد نوینی برای مشخص کردن این تعداد دسته بهینه ارائه کرد.

منابع

۱. حسینی، منیره السادات. (۱۴۰۰). بررسی اثر ابعاد اکوسیستم فناوری مالی بر مدل‌های کسب‌وکار، تصمیم‌گیری‌های سرمایه‌گذاری و چالش‌های مالی. *اولین کنفرانس بین‌المللی جهش علوم مدیریت، اقتصاد و حسابداری*. ساری.
۲. معدنچی زاج، مهدی و حیدرزاده اقدم، نرجس. (۱۳۹۸). امکان‌سنجی تأمین مالی از طریق وام‌دهی همتابه‌همتا از دیدگاه اجرائی، فقهی و اقتصادی، *شانزدهمین کنفرانس بین‌المللی مدیریت (علمی-پژوهشی)*. تهران.
3. Ayantola, A. (2020). *Minimizing Credit Risk In Peer-to-Peer Lending Business Using Supervised Machine Learning Techniques*. Masters thesis, Dublin, National College of Ireland.
4. Babaei, G., & Bamdad, S. (2020). A multi-objective instance-based decision support system for investment recommendation in peer-to-peer lending. *Expert Systems with Applications, 150*, 113278.
5. Duan, J. (2019). Financial system modeling using deep neural networks (DNNs) for effective risk assessment and prediction. *Journal of the Franklin Institute, 356*(8), 4716-4731.
6. Fernandez, C., Provost, F., & Han, X. (2019). Counterfactual explanations for data-driven decisions. *40th International Conference on Information Systems*. 2019 Proceedings. 8., pp. 1-10.
7. Fernández-Loría, C., Provost, F., & Han, X. (2020). Explaining data-driven decisions made by AI systems: the counterfactual approach. *arXiv preprint arXiv:2001.07417*.
8. Gonzalez, L. (2020), Blockchain, herding and trust in peer-to-peer lending. *Managerial Finance*, Vol. 46 No. 6, pp. 815-831.

1 Moscato, Picariello & Sperlí

9. Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*.
10. Guo, Y., Zhou, W., Luo, C., Liu, C., & Xiong, H. (2016). Instance-based credit risk assessment for investment decisions in P2P lending. *European Journal of Operational Research*, 249(2), 417-426.
11. Ha, V. S., Lu, D. N., Choi, G. S., Nguyen, H. N., & Yoon, B. (2019, February). Improving credit risk prediction in online peer-to-peer (P2P) lending using feature selection with deep learning. In *2019 21st International Conference on Advanced Communication Technology (ICACT)* (pp. 511-515). IEEE.
12. Li, H., Cao, Y., Li, S., Zhao, J., & Sun, Y. (2020). XGBoost model and its application to personal credit evaluation. *IEEE Intelligent Systems*, 35(3), 52-61.
13. Liu^l, Y., Ma, H., Jiang, Y., & Li, Z. (2021). Modelling risk and return awareness for p2p lending recommendation with graph convolutional networks. *Applied Intelligence*, 1-16.
14. Liu^{ll}, Y., Ma, H., Jiang, Y., & Li, Z. (2021). Learning to recommend via random walk with profile of loan and lender in P2P lending. *Expert Systems with Applications*, 174, 114763.
15. Majumder, C., & Kim, T. (2021, May 5). *LendingClub investments - loan default & investor ROI*. Nationally Accredited Data Science Academy. Retrieved August 19, 2022, from <https://nycdatascience.com/blog/student-works/investment-in-lendingclub-loan-default-investor-roi-prediction/>
16. Milne, A., & Parboteeah, P. (2016). The business models and economics of peer-to-peer lending. *ECRI Research Report*, No 17.
17. Moscato, V., Picariello, A., & Sperlí, G. (2021). A benchmark of machine learning approaches for credit score prediction. *Expert Systems with Applications*, 165, 113986.
18. Mothilal, R. K., Sharma, A., & Tan, C. (2020, January). Explaining machine learning classifiers through diverse counterfactual explanations. In *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency* (pp. 607-617).
19. Namvar, A., Siami, M., Rabhi, F., & Naderpour, M. (2018). Credit risk prediction in an imbalanced social lending environment. *arXiv preprint arXiv:1805.00801*.
20. Niu, K., Zhang, Z., Liu, Y., & Li, R. (2020). Resampling ensemble model based on data distribution for imbalanced credit risk evaluation in P2P lending. *Information Sciences*, 536, 120-134.
21. Rao, C., Liu, M., Goh, M., & Wen, J. (2020). 2-stage modified random forest model for credit risk assessment of P2P network lending to "Three Rurals" borrowers. *Applied Soft Computing*, 95, 106570.
22. Song, Y., Wang, Y., Ye, X., Wang, D., Yin, Y., & Wang, Y. (2020). Multi-view ensemble learning based on distance-to-model and adaptive clustering for imbalanced credit risk assessment in P2P lending. *Information Sciences*, 525, 182-204.
23. Victor, L. (2021). Loan Default Prediction Using Genetic Algorithm: A Study Within Peer-To-Peer Lending Communities. *International Journal of Innovative Science and Research Technology*, 6(3), 1195-1205.
24. Wang, Z., Jiang, C., Ding, Y., Lyu, X., & Liu, Y. (2018). A novel behavioral scoring model for estimating probability of default over time in peer-to-peer lending. *Electronic Commerce Research and Applications*, 27, 74-82.
25. Wijnands, M. P. J. (2021). *Explaining black box decision-making: adopting explainable artificial intelligence in credit risk prediction for P2P lending* (Master's thesis, University of Twente).
26. Xia, Y., Liu, C., & Liu, N. (2017). Cost-sensitive boosted tree for loan evaluation in peer-to-peer lending. *Electronic Commerce Research and Applications*, 24, 30-49.
27. Xie, Y., Li, X., Ngai, E. W. T., & Ying, W. (2009). Customer churn prediction using improved balanced random forests. *Expert Systems with Applications*, 36(3), 5445-5449.
28. Zhou, J., Li, W., Wang, J., Ding, S., & Xia, C. (2019). Default prediction in P2P lending from high-dimensional data based on machine learning. *Physica A: Statistical Mechanics and its Applications*, 534, 122370.

