

ترکیب تکنیک‌های انتخاب نمونه و داده‌افزایی برای حل مسئله طبقه‌بندی مجموعه داده‌های نامتوازن

پرستو محقق، سمیرا نوفrstی و مهری رجائی

در میان تکنیک‌های مختلف داده‌کاوی، طبقه‌بندی^۱ از تکنیک‌هایی است که بیشترین استفاده را برای مسائل مختلف داراست؛ مانند پیش‌بینی ورکستگی و تشخیص سلطان [۱] و [۲]. طبقه‌بندی یکی از روش‌های یادگیری ماشین است که بر اساس یک مجموعه داده آموزشی از نمونه‌های برچسب‌خورده به ساخت یک مدل پیش‌بینی کننده می‌پردازد که قادر است برچسب کلاس نمونه‌های جدید را تعیین کند.

یکی از مشکلاتی که الگوریتم‌های طبقه‌بندی با آن مواجه هستند، مجموعه داده‌های نامتوازن است. مشکل عدم توازن زمانی رخ می‌دهد که تعداد نمونه‌ها در یک کلاس (که کلاس اقلیت^۲ نامیده می‌شود) در مقایسه با سایر کلاس‌ها بسیار کمتر باشد؛ در حالی که کلاس اقلیت از لحاظ کاربرد اهمیت فراوانی دارد. به عنوان مثال می‌توان به مسائل زیر اشاره کرد. در شناسایی آفت‌های کشاورزی، برخی آفتها پرخاده هستند و به کرات نمونه دارند و برخی آفتها به ندرت مشاهده می‌شوند و به همین دلیل، تعداد نمونه‌های کمی دارند [۳]. در تشخیص نفوذ به شبکه‌های کامپیوترا (تشخیص ترافیک نرمال از ترافیک غیرنرمال شبکه) و تشخیص اشیا-جایی که اغلب تصاویر مجموعه آموزش فاقد شیء مورد نظر هستند- نیز برخی از کلاس‌ها تعداد نمونه‌های کمی دارند [۴].

برای حل مشکل مجموعه داده‌های نامتوازن، رویکردهای متعددی در سه سطح داده، مدل و ترکیبی ارائه شده‌اند. هدف رویکردهای سطح داده کاهش نسبت عدم تعادل بین کلاس‌های اکثربیت^۳ و اقلیت با انتخاب نمونه^۴ کلاس اکثربیت یا داده‌افزایی^۵ در کلاس اقلیت است [۵] و [۶]. رویکردهای سطح مدل عمدتاً توابع حساس به هزینه^۶ را معرفی می‌کنند [۷]. رویکردهای این سطح غالباً شامل روش فرایادگیری^۷ و روش یادگیری انتقالی^۸ هستند [۸] و [۹]. روش‌های ترکیبی نیز مزایای رویکردهای سطح داده و سطح مدل را ترکیب می‌کنند.

در این مقاله بر رویکرد سطح داده برای حل مشکل داده‌های نامتوازن مرکز می‌شویم. رویکردهای سطح داده که به طور گسترده استفاده می‌شوند با تعادل‌سازی مجموعه داده نامتوازن، بهبود نتایج یادگیری ماشین را به دنبال دارند. الگوریتم‌های طبقه‌بندی سنتی بر روی داده‌های نامتوازن عملکرد مناسبی ندارند؛ زیرا فرض می‌کنند که تعداد نمونه‌های

چکیده: در عصر کلان‌داده‌ها، تکنیک‌های تجزیه و تحلیل خودکار مانند داده‌کاوی به طور گسترده‌ای برای تصمیم‌گیری به کار گرفته شده و بسیار مؤثر واقع شده‌اند. از جمله تکنیک‌های داده‌کاوی می‌توان به طبقه‌بندی اشاره کرد که یک روش رایج برای تصمیم‌گیری و پیش‌بینی است. الگوریتم‌های طبقه‌بندی به طور معمول بر روی مجموعه داده‌های متوازن به خوبی عمل می‌کنند. با وجود این، یکی از مشکلاتی که الگوریتم‌های طبقه‌بندی با آن مواجه هستند، پیش‌بینی صحیح برچسب نمونه‌های جدید بر اساس یادگیری بر روی مجموعه داده‌های نامتوازن است. در این نوع از مجموعه داده‌ها، توزیع ناهمگونی که داده‌ها در کلاس‌های مختلف دارند باعث نادیده گرفته شدن نمونه‌های کلاس در برخی مسائل کمتر در یادگیری طبقه‌بندی می‌شوند؛ در حالی که این کلاس در برخی مسائل پیش‌بینی دارای اهمیت بیشتری است. بهمنظور مقابله با مشکل مذکور در این مقاله، روشی کارا برای تعادل‌سازی مجموعه داده‌های نامتوازن ارائه می‌شود که با تعادل‌نمودن تعداد نمونه‌های کلاس‌های مختلف در مجموعه داده‌ای نامتوازن، پیش‌بینی صحیح برچسب کلاس نمونه‌های جدید توسط الگوریتم یادگیری ماشین را بهبود می‌بخشد. بر اساس ارزیابی‌های صورت گرفته، روش پیشنهادی بر اساس دو معیار رایج در ارزیابی طبقه‌بندی مجموعه داده‌های نامتوازن به نام‌های «صحبت متعادل» و «ویژگی»، عملکرد بهتری در مقایسه با روش‌های دیگر دارد.

کلیدواژه: انتخاب نمونه، داده‌افزایی، طبقه‌بندی، مجموعه داده نامتوازن، داده‌کاوی، یادگیری ماشین.

۱- مقدمه

حجم کلان‌داده‌ها به گونه‌ای عظیم است که چالش‌های ذخیره‌سازی و تحلیل داده‌ها، کشف دانش و پیچیدگی محاسباتی را به دنبال دارد. از جمله کلان‌داده‌ها می‌توان به پروژه زنوم انسان^۹ اشاره کرد که چندین گیگابایت داده را از کد ژنتیکی انسان تجمعی کرده است. داده‌کاوی، مجموعه‌ای از روش‌های قابل اعمال بر مجموعه داده‌های بزرگ و پیچیده بهمنظور کشف الگوهای پنهان در میان داده‌هاست.

این مقاله در تاریخ ۱۹ اسفند ماه ۱۴۰۱ دریافت و در تاریخ ۹ مرداد ماه ۱۴۰۲ بازنگری شد.

پرستو محقق، دانشکده مهندسی برق و کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران، (email: P.mohaghegh@pgs.usb.ac.ir).

سمیرا نوفrstی (نویسنده مسئول)، دانشکده مهندسی برق و کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران، (email: snoferesti@ece.usb.ac.ir).

مهری رجائی، دانشکده مهندسی برق و کامپیوتر، دانشگاه سیستان و بلوچستان، زاهدان، ایران، (email: rajayi@ece.usb.ac.ir).

1. Human Genome

2. Classification
3. Minority Class
4. Majority Class
5. Instance Selection
6. Data Augmentation
7. Cost-Sensitive Functions
8. Meta-Learning
9. Transfer Learning

روش‌های رپر هستند و برای مجموعه داده‌ها با ابعاد بزرگ نیز مناسب هستند. از جمله این روش‌ها می‌توان به روش پایه POP [۱۴] اشاره کرد. این روش، نمونه‌های مرکزی را حذف و نمونه‌های مرزی را حفظ می‌کند. در متدهای POP مقدار Weakness برای هر یک از نمونه‌ها حساب می‌شود که نشانگر تعداد دفعاتی می‌باشد که نمونه مدنظر به عنوان نمونه مرکزی شناخته شده است. پس از آن، نمونه‌هایی که مقدار Weakness برایشان برابر تعداد ویژگی‌ها باشد، به عنوان نمونه مرکزی شناخته می‌شوند و حذف می‌گردد. در [۱۰] یک روش فیلتر برای انتخاب نمونه پیشنهاد شده که بر بهینه‌کردن سه معیار همبستگی، افزونگی و سازگاری داده‌ها به صورت همزمان تمرکز می‌کند. در این روش، قیود حفظ نمونه بر مدل‌های بهینه‌سازی تحمیل می‌شوند تا حداقل درصد نمونه‌هایی را که توسط تصمیم‌گیرنده ایجاد شده است حفظ کنند.

از جمله روش‌های رپر پایه می‌توان به مدل‌های DROP₁₋₅ از ویلسون و مارتینز [۱۵] اشاره کرد که در آن، ترتیب حذف نمونه‌ها اهمیت دارد. بدین صورت که اگر حذف یک نمونه P از مجموعه کاهش‌یافته S بر دقت طبقه‌بند تأثیری نداشته باشد، آن نمونه از S حذف می‌شود. این مدل‌ها به ویژه DROP₃ پایه سیاری از روش‌های جدید انتخاب نمونه هستند [۱۱].

تیسای و همکاران [۵] روشی را با نام^۳ CBIS پیشنهاد دادند که در آن، مجموعه آموزش نامتوازن با دو کلاس اکثریت و اقلیت بررسی می‌گردد. در گام اول از کلاس اقلیت صرف نظر می‌شود و الگوریتم خوشبندی، نمونه‌های مشابه از کلاس اکثریت را در تعدادی خوشه‌بندی می‌کند که به عنوان زیرکلاس‌هایی از کلاس اکثریت شناخته می‌شوند. سپس در گام بعد، الگوریتم انتخاب نمونه پایه مانند الگوریتم ژنتیک بر روی کلیه خوشه‌ها عمل فیلتر را انجام می‌دهد و دو مجموعه داده کاهش‌یافته با نمونه‌های نویزدار و بدون نویز ایجاد می‌شوند. مجموعه با نمونه‌های نویزدار کنار گذاشته می‌شود و مجموعه داده کاهش‌یافته نهایی بدون نویز انتخاب می‌گردد. سپس مجموعه داده کاهش‌یافته نهایی از کلاس اکثریت با نمونه‌های کلاس اقلیت ترکیب شده و به عنوان مجموعه آموزشی جدید به طبقه‌بند جهت ارزیابی عملکرد داده می‌شود. نتایج تجربی نشان می‌دهند بعد از اعمال روش CBIS بر روی مجموعه داده نامتوازن، نسبت عدم توازن مجموعه تا حدی کاهش می‌یابد.

در [۱۶] روشی مبتنی بر یادگیری تقویتی برای انتخاب نمونه پیشنهاد شد که ابتدا خوشه‌هایی از نمونه‌ها را بر اساس یک معیار شباهت می‌سازد. سپس عاملی را در نظر می‌گیرد که می‌تواند تدریجاً داده‌ها را به مجموعه کاهش‌یافته نهایی اضافه کند. در یک حلقه، این عامل خوشه‌ای از نمونه‌ها (عمل) را برای اضافه‌شدن به نمونه‌های انتخاب شده (حالت)، انتخاب و پاداشی متناسب با کاهش خطای مدل پیش‌بینی کننده دریافت می‌کند. خروجی الگوریتم (سیاست عامل) ماتریسی است که توازن بین بهبود مدل و اندازه داده‌ها را نشان می‌دهد. هر درایه از ماتریس، ارزش افزودن یک خوشه به نمونه‌های موجود را نشان می‌دهد و این ماتریس توانایی متعادل کردن اهداف کاهش نویز و حجم داده را دارد.

در مقاله حاضر نیز یک تکنیک یادگیری تقویتی به نام اتماتای یادگیر برای انتخاب نمونه پیشنهاد شده و نتایج مطالعات پیشین، موفقیت‌آمیز بودن به کارگیری اتماتای یادگیر را برای حل مسائل بهینه‌سازی پیچیده که شامل عدم قطعیت، غیرخطی بودن و متغیرهای تصمیم‌گیری چندگانه

آموزشی از هر کلاس با هم یکسان هستند و طبقه‌بند را بر مبنای این فرض آموزش می‌دهند. در واقع، زمانی که تعداد نمونه‌ها در کلاس اکثریت بیشتر از کلاس اقلیت باشد، الگوریتم یادگیری ماسین بیشتر به کلاس اکثریت توجه می‌کند و کلاس اقلیت را نادیده می‌گیرد؛ در حالی که در بسیاری از مسائل واقعی، پیش‌بینی صحیح برچسب نمونه‌های کلاس اقلیت دارای اهمیت بیشتری است. بنابراین این امر سبب پیش‌بینی ضعیف نمونه‌های کلاس اقلیت می‌شود؛ زیرا کلاس اقلیت به درستی آموزش داده نشده است. برای حل مشکل مذکور تکنیک‌های متعددی برای متعادل‌سازی مجموعه داده‌های نامتوازن معرفی شده‌اند.

به طور کلی، تکنیک‌های موجود برای حل مسئله مجموعه داده‌های نامتوازن به دو دسته انتخاب نمونه و داده‌افزایی تقسیم می‌شوند. روش‌های انتخاب نمونه، سعی در کاهش تعداد نمونه‌های کلاس اکثریت بهمنظور رسیدن به تعادل نسبی در اندازه کلاس‌ها دارند [۱۰] و [۱۱]. در روش‌های انتخاب نمونه، گاهی بخش عمده‌ای از اطلاعات که برای تهیه و برچسب‌گذاری آنها زمان و هزینه زیادی صرف شده است، از دست می‌روند و مشکل انتخاب نمونه بیش از حد رخ می‌دهد که منجر به کاهش عملکرد طبقه‌بند می‌شود.

در روش‌های داده‌افزایی، الگوریتم‌های نمونه‌برداری به صورت تصادفی یا از مناطقی که اهمیت بیشتری برای کاربر دارد، نمونه‌های کلاس اقلیت را کپی‌برداری می‌کنند تا زمانی که تعادل بین نمونه‌های کلاس اقلیت و اکثریت حاصل شود [۱۲] و [۱۳]. در عین سادگی این روش‌ها، مشکلی که وجود دارد این است که نمونه مورد نظر از کلاس اقلیت برای انجام تکرار مشخص نیست.

برای اجتناب از مشکلات ذکر شده، در این مقاله روشی ترکیبی ارائه می‌شود که از مزایای هر دو روش انتخاب نمونه و داده‌افزایی بهره می‌برد. در روش پیشنهادی، ابتدا با ترکیب دو روش داده‌افزایی به گسترش مجموعه اقلیت پرداخته می‌شود و سپس با به کارگیری یک روش انتخاب نمونه مبتنی بر اتماتای یادگیر^۱، نمونه‌هایی از کلاس اقلیت گسترش‌یافته گسترش‌یافته که تأثیر بیشتری بر دقت مدل پیش‌بینی کننده دارد، انتخاب می‌شوند. نتایج آزمایش‌های انجام گرفته، کارایی روش پیشنهادی را در مقایسه با روش‌های موجود نشان می‌دهند.

ادامه مقاله به صورت زیر سازمان‌دهی شده است: در بخش ۲ به معرفی تحقیقات پیشین در زمینه طبقه‌بندی داده‌های نامتوازن پرداخته می‌شود. در بخش ۳ جزئیات روش پیشنهادی شرح داده می‌شود. در بخش ۴ ارزیابی کارایی روش پیشنهادی و مقایسه نتایج آن با سایر روش‌های موجود ارائه می‌گردد و در پایان، بخش ۵ نتیجه‌گیری است.

۲- مرور تحقیقات پیشین

تکنیک‌های متعادل‌سازی مجموعه داده‌های نامتوازن در کارهای پیشین را به طور کلی می‌توان به دو دسته انتخاب نمونه و داده‌افزایی تقسیم کرد.

۱-۲ تکنیک‌های انتخاب نمونه

تکنیک‌های انتخاب نمونه به دو دسته کلی فیلتر و رپر دسته‌بندی می‌شوند. تکنیک‌های فیلتر اغلب به رویکرد نزدیک‌ترین همسایگان یک نمونه جهت حذف یا حفظ آن وابسته هستند. روش‌های فیلتر بر اساس تابع انتخاب نمونه عمل می‌کنند و از لحاظ محاسباتی بسیار سریع‌تر از

نمونه از کلاس اقلیت با مرکز، محاسبه و نمونه جدید در سطح اول تولید می‌گردد. این عمل برای نمونه‌های جدید و نمونه‌های کلاس اقلیت در سطح دوم نیز تکرار می‌شود. گرچه روش H-SMOTE عملکرد بهتری نسبت به الگوریتم‌های پایه مانند SMOTE دارد، اما همچنان مشکل کافی نبودن نمونه‌های تولید شده در سطح اول و دوم برای متوازن‌سازی با افزایش نرخ عدم توازن را دارد.

در تحقیقی دیگر، بیج و همکاران [۱۳] یک روش داده‌افزایی را با نام LoRAS^۳ معرفی کردند. در این روش برای هر نمونه P از کلاس اقلیت، محلی چندضلعی در نظر گرفته شده و سپس k نزدیک‌ترین همسایه‌های نمونه P مطابق محل آن انتخاب می‌شوند. برای هر نمونه که در همسایگان نمونه P قرار دارد به اندازه ممینی، نمونه سایه ایجاد می‌گردد. نمونه‌های سایه به‌وسیله تعدادی نویز با توجه به توزیع نرمال با انحراف معیار استاندارد ایجاد می‌شوند. سپس به صورت تصادفی به تعداد ویژگی‌ها از لیست نمونه‌های سایه، نمونه انتخاب می‌گردد و در وزن‌های بردار آفین ضرب می‌شوند و خروجی بردار به عنوان نمونه جدید در نظر گرفته می‌شود. اگر F یک میدان و V یک فضای برداری روی F باشد که اعضای F اسکالر و v_i ها ($i = 1, 2, \dots, n$) (که $V = \lambda_1 v_1 + \lambda_2 v_2 + \dots + \lambda_n v_n$) باشند، آن گاه ترکیب خطی $V' = \lambda'_1 v_1 + \lambda'_2 v_2 + \dots + \lambda'_n v_n$ یک ترکیب آفین نامیده می‌شود اگر $\sum_j \lambda_j = 1$ باشد [۱۸].

مسئله متعادل‌سازی مجموعه داده‌های نامتوازن، همچنان مسئله‌ای چالش‌برانگیز برای پژوهشگران است. در این مقاله یک روش ترکیبی مبتنی بر داده‌افزایی و انتخاب نمونه با درنظرگرفتن اهمیت حفظ نمونه‌ها بر مبنای عملکرد طبقه‌بندها ارائه شده است.


۳- روش پیشنهادی

روش پیشنهادی متمرکز بر بهره‌مندی از مزایای هر دو روش انتخاب نمونه و داده‌افزایی برای افزایش کارایی الگوریتم‌های یادگیری ماشین است. مطالعات کارهای پیشین نشان داده که انتخاب نمونه و داده‌افزایی، تأثیر شایانی در افزایش دقت الگوریتم‌های یادگیری ماشین دارد. با وجود این، استفاده از روش‌های انتخاب نمونه و داده‌افزایی به‌طور مستقل مشکلاتی را به همراه دارد. روش‌های انتخاب نمونه موجب حذف نمونه‌هایی می‌شوند که برای جمع‌آوری و برچسب‌گذاری آنها وقت و هزینه بسیاری صرف شده و روش‌های داده‌افزایی منجر به تولید نمونه‌های تکراری متعدد و غیرکاربردی می‌شوند. لذا برای حل مشکل ذکر شده در پژوهش حاضر، روش ترکیبی مبتنی بر هر دو روش انتخاب نمونه و داده‌افزایی برای متوازن‌ساختن دو کلاس اقلیت و اکثریت مجموعه داده و همین طور بهبود دقت الگوریتم‌های یادگیری ماشین ارائه می‌شود.

روش پیشنهادی برای متوازن‌سازی کلاس اقلیت و اکثریت که به ترتیب با C_{min} و C_{maj} نشان داده می‌شوند، دو مرحله اصلی دارد: ۱) داده‌افزایی کلاس اقلیت C_{min} با ترکیب دو روش شناخته شده H-SMOTE [۱۲] و LoRAS [۱۳] که منجر به ایجاد یک مجموعه جدید از رکوردهای آموزشی به نام کلاس اقلیت گسترش‌یافته (C'_{min}) می‌شود و ۲) انتخاب نمونه با اتمماتیک‌های یادگیر بر روی کلاس C'_{min} . مراحل روش پیشنهادی در شکل ۱ نشان داده شده‌اند. در ادامه جزئیات هر مرحله تشریح می‌گردد.

۱- مرحله اول: داده‌افزایی

روش‌های داده‌افزایی، سعی در افزایش نمونه‌های کلاس اقلیت با هدف




شکل ۱: مراحل روش پیشنهادی.

هستند، نشان می‌دهد. در زمینه انتخاب نمونه، اتمماتی یادگیر می‌تواند طی یک فرایند تکرارشونده به یافتن زیرمجموعه بهینه (یا نزدیک به بهینه) از نمونه‌ها با تنظیم مکرر آنها بر اساس بازخورد دریافتی از محیط کمک کند. از جمله مزایای اتمماتی یادگیر، عدم نیاز به داشتن صریح درباره مسئله بهینه‌سازی است؛ مثل اطلاعاتی مانند ساختار مسئله و محدودیت‌هایی که باید برآورده شوند. علاوه بر این، اتمماتی یادگیر می‌تواند با کاوش مؤثرتر در فضای راه حل‌های ممکن، مسائل با ابعاد بالا را به نحو مؤثرتری مدیریت کند.

۲- تکنیک‌های داده‌افزایی

ایده اصلی در روش‌های داده‌افزایی، گسترش تعداد نمونه‌های کلاس اقلیت برای متوازن‌سازی توزیع نمونه‌ها بین کلاس‌ها است. روش SMOTE^۴ در بین روش‌های داده‌افزایی از محبویت بیشتری برخوردار است [۱۷]. ایده اصلی این روش به این صورت است که در کلاس اقلیت برای هر نمونه P با توجه به میزان شباهتی که با دیگر نمونه‌های کلاس اقلیت دارد، k نزدیک‌ترین همسایگانش از درون کلاس اقلیت تعیین می‌گردد و سپس بین هر دو نمونه از همسایگان، نمونه‌های جدید به صورت تصادفی تولید می‌شوند. مشکلی که روش SMOTE دارد این است که نمی‌تواند به خوبی بر مشکل توزیع نامتوازن داده‌ها غلبه کند؛ به دلیل اینکه ناحیه تولید نمونه‌ها (کلاس اقلیت) محدود است و فاصله نمونه‌های مرکزی تولید شده در مجموعه داده‌ای جدید با نمونه‌های مرکزی مجموعه داده آموزشی اصلی زیاد می‌شود. چنان و ژانگ [۱۲] نیز روش H-SMOTE را با هدف تولید نمونه‌های جدید یکنواخت‌تر و نزدیک‌تر به مرکز کلاس اقلیت معرفی کردند. در این روش عملیات صورت گرفته به‌طور عمده از دو عمل نمونه‌برداری و فیلتر نمونه‌های نویزدار تشکیل شده است. ابتدا نمونه مرکزی کلاس اقلیت با میانگین‌گیری از ویژگی‌ها مشخص می‌شود و سپس فاصله منتهن هر



شکل ۳: داده‌افزایی مبتنی بر الگوریتم [۱۲] H-SMOTE

مجموعه داده‌های بسیار نامتسوازن و با ابعاد بالا را دارد [۱۳]. در ادامه به معرفی دقیق‌تر این دو الگوریتم می‌پردازیم.

شکل ۲ الگوریتم داده‌افزایی LoRAS را نمایش می‌دهد. در این الگوریتم در فضای F بعدی (که F تعداد ویژگی‌هاست) برای هر نمونه p از کلاس اقلیت که با C_{\min} نمایش داده می‌شود، محلی t ضلعی در نظر گرفته شده که به صورت پیش‌فرض، چندضلعی منتظم مانند مکعب مستطیل است. سپس k نزدیک‌ترین همسایه‌های نمونه p مطابق محل p مستطیل است. سپس q والد که در همسایگان نمونه p قرار دارند، مطابق (۱) به اندازه $|S_p|$ نمونه سایه ایجاد می‌شود

$$|S_p| = \max\left(\frac{2|F|}{k}, 40\right) \quad (1)$$

که مقدار ۴۰ حداکثر تعداد نمونه‌های سایه برای یک نمونه والد را نشان می‌دهد. نمونه‌های سایه به وسیله تعدادی نویز با توجه به توزیع نرمال با انحراف معیار استاندارد L_σ ایجاد می‌شوند و مقدار پیش‌فرض آن [۰,۰۰۵, ..., ۰,۰۰۵] می‌باشد. سپس به صورت تصادفی به اندازه N_{aff} که پیش‌فرض تعداد ویژگی‌ها است از لیست نمونه‌های سایه، نمونه انتخاب شده و طبق (۲) در وزن‌های بردار آفین ضرب می‌شوند و خروجی بردار به عنوان نمونه جدید به مجموعه نمونه‌های LoRAS افزوده می‌شود $\alpha_1 + \alpha_2 + \alpha_3 = 1$. یک بردار آفین با وزن‌های تصادفی به صورت (۲) به دست می‌آید


$$L = \alpha_1 s_1 + \alpha_2 s_2 + \alpha_3 s_3 \quad (2)$$

این الگوریتم تا زمانی که تعداد نمونه‌ها برای هر گروه نزدیک‌ترین همسایگی مطابق (۳) به اندازه N_{gen} نرسد، اجرا می‌شود که $|C_{\min}|$ تعداد نمونه‌های کلاس اقلیت و $|C_{\max}|$ تعداد نمونه‌های کلاس اکثربت را نشان می‌دهد


$$N_{gen} = \frac{|C_{\max}| - |C_{\min}|}{|C_{\min}|} \quad (3)$$

در الگوریتم H-SMOTE، نمونه‌های اقلیت و اکثربت به عنوان ورودی به الگوریتم داده می‌شوند و خروجی الگوریتم، مجموعه داده‌ای از جنس کلاس اقلیت است که نمونه تکراری در آن وجود ندارد. مطابق شکل ۳، در ابتدا برای به دست آوردن نمونه مرکزی Z در کلاس اقلیت، میانگین نمونه‌های کلاس اقلیت (نقاط آبی) محاسبه می‌شود. سپس در سطح اول برای هر نمونه p_i از کلاس اقلیت مطابق (۴) با محاسبه فاصله منهنه، نمونه جدید x_i میان نمونه مرکزی Z و نمونه p_i تولید می‌شود و در کلاس اقلیت قرار می‌گیرد (نقاط قرمز) [۱۲]


$$x_i = p_i + 0.5 \times (Z - p_i) \quad (4)$$




(الف)



(ب)




(ج)



شکل ۲: مصورسازی گام به گام روش داده‌افزایی LoRAS [۱۳].

متداول‌سازی توزیع نمونه‌ها بین کلاس‌ها دارند. از آنجا که روش پیشنهادی مقاله حاضر، سعی در متداول‌سازی کلاس اقلیت با کلاس اکثربت دارد، ابتدا داده‌افزایی کلاس اقلیت با دو الگوریتم LoRAS [۱۳] و H-SMOTE [۱۲] صورت می‌گیرد. دلیل انتخاب دو الگوریتم مذکور، محبوبیت و نتایج موفقیت‌آمیز آنها در مقایسه با روش‌های موجود است. الگوریتم H-SMOTE دو مزیت اصلی دارد: توزیع پایدار و یکنواخت نمونه‌های تولیدشده و کارایی الگوریتم در مقایسه با روش‌های موجود [۱۲]. الگوریتم LoRAS همچنین علاوه بر کارایی بالا، توانایی مدیریت



شکل ۴: روندnamای الگوریتم انتخاب نمونه.

از آنجا که تعداد نمونه‌های تولیدشده در سطح اول برابر با تعداد نمونه‌های کلاس اقلیت است، اگر تعداد نمونه‌های کلاس اکثیریت و نمونه‌های کلاس اقلیت را به ترتیب A و B نام‌گذاری کنیم، آنگاه تعداد نمونه‌های تولیدشده در سطح دوم باید $A - 2 \times B$ باشد. بنابراین به طور تصادفی دو نمونه x_i و x_j از نمونه‌های سطح اول که مساوی نیستند برای محاسبه فاصله منهنه انتخاب می‌شوند و سپس مطابق (۵) نمونه جدید x_{ii} در سطح دوم ایجاد می‌گردد (نقاط بنشن) [۱۲]

$$x_{ii} = x_i + 0.5 \times (x_j - x_i) \quad (5)$$

نتیجتاً نمونه‌های تکراری، فیلتر و نمونه‌های جدید حاصل می‌شوند. این الگوریتم تا زمانی که تعداد نمونه‌های جدید، بزرگ‌تر یا مساوی کلاس اکثیریت نباشد، ادامه می‌یابد تا همان طور که گفته شد، تعداد نمونه‌های سطح دوم برابر $A - 2 \times B$ شود.

همان طور که گفته شد، داده‌افزایی تنها بر روی کلاس اقلیت C_{\min} انجام می‌شود و حاصل آن کلاس اقلیت گسترش یافته C'_{\min} است. از آنجا که هر دو روش H-SMOTE و LoRAS سعی دارند تعداد نمونه‌های کلاس اقلیت را به تعداد نمونه‌های کلاس اکثیریت برسانند، با اعمال توازن هر دو روش به تعادل نسبی در تعداد نمونه‌های کلاس‌های اقلیت و اکثیریت نمی‌رسیم؛ بلکه تعداد نمونه‌های کلاس اقلیت گسترش یافته C'_{\min} بیشتر از تعداد نمونه‌های کلاس اکثیریت C_{maj} می‌شود. برای حل این مشکل، پس از داده‌افزایی با دو روش LoRAS و H-SMOTE داده خروجی آنها ترکیب شده (که آن را D می‌نامیم) و برای مرحله دوم (انتخاب نمونه) به کار گرفته می‌شود. مجموعه D شامل کلیه رکوردهای

۴- نتایج

در این بخش به ارزیابی کارایی روش پیشنهادی برای معادل‌سازی مجموعه داده‌های نامتوازن پرداخته می‌شود. در ابتدا ابزار، مجموعه داده‌های نامتوازن مورد استفاده و تنظیمات پیاده‌سازی معرفی می‌گردد و سپس نتایج آزمایش‌های انجام گرفته ارائه می‌شود.

۴-۱ مجموعه داده‌های مورد استفاده، ابزار و تنظیمات پیاده‌سازی

جهت پیاده‌سازی روش پیشنهادی برای معادل‌سازی مجموعه داده‌های نامتوازن از ابزار Jupyter notebook [۲۰] استفاده شده است.

نرم‌افزار Jupyter notebook تحت زبان Python ۳.۶ اجرا می‌شود. مجموعه داده‌های نامتوازن، یک مورد خاص برای مسئله طبقه‌بندی هستند که توزیع نمونه‌ها در آنها در بین کلاس‌ها یکنواخت نیست. این مجموعه‌ها معمولاً دو کلاس اکثربت (positive) و اقلیت (negative) دارند. روش پیشنهادی بر روی ۸ مجموعه داده نامتوازن انتخاب شده از مخزن داده KEEL^۳ ارزیابی شده است. در این مقاله از مجموعه داده‌های دودوبی^۴ Ecoli^۵, Glass^۶, Yeast^۷, Abalone^۸, Yeast^۹, Yeast^{۱۰}, Page-blocks^{۱۱} و استفاده گردیده که در دسته‌های مختلفی از نسبت عدم توازن^{۱۲} (IR) قرار دارند؛ از مجموعه داده‌های نامتوازن با IR کم تا IR بسیار بالا. نسبت عدم توازن IR طبق (۸) محاسبه می‌گردد

$$IR = \frac{N_{maj}}{N_{min}} \quad (8)$$

که N_{min} تعداد نمونه‌های کلاس اقلیت و N_{maj} تعداد نمونه‌های کلاس اکثربت را نشان می‌دهد. هرچه نسبت عدم توازن (IR) به ۱ نزدیک‌تر باشد، آن مجموعه داده‌ای معادل‌تر است. در جدول ۱ خلاصه‌ای از مشخصات مجموعه داده‌های مذکور آورده شده است.

طبق جدول ۲ در روش LoRAS به k در صورتی که $|C_{min}| \geq 100$ باشد، به صورت پیش‌فرض مقدار ۳۰ داده می‌شود و در غیر این صورت مقدار ۵ می‌گیرد. اندازه N_{aff} برابر تعداد ویژگی‌های است. مقادیر پارامترهای روش LoRAS بر اساس [۱۳] انتخاب شده است.

۴-۲ ارزیابی روش پیشنهادی برای معادل‌سازی مجموعه داده‌های نامتوازن

روش پیشنهادی با الگوریتم‌های H-SMOTE [۱۲] و LoRAS [۱۳] مقایسه شده است. در دو الگوریتم مذکور تنها به افزایش تعداد نمونه‌های کلاس اقلیت پرداخته شده و همچنان عدم توازن زیادی در مجموعه داده‌های حاصل مشهود است. در روش پیشنهادی با انجام انتخاب نمونه بر روی ترکیب مجموعه داده‌های حاصل از دو الگوریتم، نسبت عدم توازن به طور قابل توجهی کاهش می‌یابد و توازن نسبی حاصل می‌گردد.

در شکل ۵ نسبت عدم توازن دو کلاس اقلیت و اکثربت برای روش پیشنهادی (با به کارگیری طبقه‌بندهای KNN و SVM) و دو الگوریتم داده‌افزایی مذکور آمده است. همان طور که مشاهده می‌شود، نسبت عدم توازن در روش پیشنهادی با هر دو طبقه‌بند نسبت به دو روش دیگر به ۱ نزدیک‌تر است. به عنوان مثال نسبت عدم توازن در مجموعه داده حاصل

فرایند کار بدین صورت است که به هر نمونه (رکورد) i در کلاس C'_{min} از مجموعه داده ترکیبی (D) حاصل از مرحله اول، یک اتوماتای LA_i یادگیر LA_i تعلق می‌گیرد. هر اتوماتای LA_i بر اساس احتمال $p_i(t)$ که متناظر با عمل انتخاب نمونه i در تکرار t است، یک عمل انتخاب یا عدم انتخاب نمونه متناظر را بر می‌گزیند. برای این منظور در تکرار t ام، اتوماتای یادگیر LA_i که متعلق به نمونه i در کلاس C'_{min} است، یک مقدار تصادفی r را تولید می‌کند و اگر $r < p_i(t)$ باشد، نمونه i در مجموعه کاهش‌یافته S_t قرار می‌گیرد که این مجموعه حاصل الگوریتم در پایان تکرار t است. در ابتدا هر نمونه از کلاس C'_{min} ، احتمالی یکسان (برابر ۰/۵) برای انتخاب یا عدم انتخاب جهت افزوده شدن به مجموعه کاهش‌یافته S_t دارد.

در پایان هر تکرار t ، یک مجموعه کاهش‌یافته به نام S_t حاصل می‌شود که شامل کلیه نمونه‌های کلاس C_{maj} و نمونه‌هایی از کلاس C'_{min} است که توسط اتوماتاهای یادگیر در تکرار t انتخاب شده‌اند. یک الگوریتم طبقه‌بندی بر روی مجموعه کاهش‌یافته S_t آموزش می‌بیند و به پیش‌بینی برچسب مجموعه داده تست T که بر اساس روش ارزیابی متقابل ۱۰-fold به دست آمده است، می‌پردازد. کارایی طبقه‌بند بر اساس معیار صحت^۱ بر روی مجموعه S_t محاسبه می‌شود و همین طور نرخ کاهش نیز حساب شده است و بر اساس نتایج به دست آمده به نمونه‌های منتخب پاداش یا جریمه تعلق می‌گیرد. بدین صورت که اگر مقدار صحت طبقه‌بند بر روی مجموعه کاهش‌یافته فعلی از بیشترین مقدار به دست آمده برای معیار صحت در تکرارهای قبلی ($Best_A$) بیشتر باشد، بردار احتمال‌های اتوماتاهای بروزرسانی شده و عمل انتخابی $Best_A$ آنها پاداش دریافت می‌کند. اگر مقدار صحت طبقه‌بند با $Best_A$ یکسان باشد و نرخ کاهش در این تکرار از نرخ کاهش در تکرارهای قبلی ($Best_Rate$) بیشتر باشد نیز عمل انتخابی اتوماتاهای یادگیر پاداش می‌گیرد. اگر خلاف این موارد باشد، آن گاه عمل انتخابی اتوماتاهای یادگیر جریمه می‌شود. بنابراین احتمال انتخاب نمونه‌های مجموعه کاهش‌یافته S_t که کارایی طبقه‌بند مد نظر را بر اساس معیار صحت بالا برده‌اند، در تکرارهای بعدی افزایش یافته و احتمال انتخاب نمونه‌های مجموعه کاهش‌یافته S_t که باعث افت کارایی طبقه‌بند بر اساس معیار صحت شده‌اند در تکرارهای بعدی کاهش می‌باید. پاداش و جریمه اتوماتاهای یادگیر به ترتیب مطابق (۶) و (۷) انجام می‌شود

$$\begin{aligned} p_i(n+1) &= p_i(n) + a[1 - p_i(n)] \\ p_j(n+1) &= (1-a)p_j(n) \quad \forall j, j \neq i \end{aligned} \quad (6)$$


$$\begin{aligned} p_i(n+1) &= (1-b)p_i(n) \\ p_j(n+1) &= \frac{b}{r-1} + (1-b)p_j(n) \quad \forall j, j \neq i \end{aligned} \quad (7)$$

که a و b دو مقدار ثابت هستند که به ترتیب پارامتر پاداش و جریمه نامیده می‌شوند. در این مقاله با سعی و خطای مقادیر این دو پارامتر ۰/۰۸ و ۰/۰۵ در نظر گرفته شده است. تا زمانی که شرط توقف (رسیدن به حداقل تکرارها) اجرایی شود، فرایند فوق ادامه خواهد داشت. در پایان الگوریتم، بهترین راه حل حاصل به عنوان مجموعه کاهش‌یافته نهایی S برگردانده می‌شود (شکل ۴). حال خروجی الگوریتم انتخاب نمونه که مجموعه داده‌ای نسبتاً متوازن است به طبقه‌بند داده می‌شود و معیارهای مدنظر بر روی مجموعه داده تست محاسبه می‌گردد.

2. <https://sci2s.ugr.es/keel/datasets.php>

3. Imbalance Rate

1. Accuracy



شکل ۵: نسبت عدم توان (IR) مجموعه داده‌ها در روش پیشنهادی، LoRAS و H-SMOTE

جدول ۱: مشخصات مجموعه داده‌های نامتوازن.

IR	تعداد نمونه‌ها	تعداد ویژگی‌ها	مجموعه داده		شناسه
			مجموعه‌های داده‌ای با IR پایین (۰ تا ۱/۵)		
۶,۳۸	۹	۲۱۴	Glass	ع	D1
۸,۱	۸	۱۴۸۴	Yeast	۳	D2
۸,۷۹	۱۰	۵۴۷۲	Page-blocks	+	D3
۸,۶	۷	۳۳۶	Ecoli	۳	D4
مجموعه‌های داده‌ای با IR بالا (بیشتر از ۰)					
۲۸,۴۱	۸	۱۴۸۴	Yeast	۴	D5
۴۱,۴	۸	۱۴۸۴	Yeast	۶	D6
۳۹,۱۴	۷	۲۸۱	Ecoli	- ۱ - ۳ - ۷ - vs - ۲ - ۶	D7
۱۲۹,۴۴	۸	۴۱۷۴	Abalone	۱۹	D8

$$\text{Balanced Accuracy} = \frac{\frac{TP}{TP+FN} + \frac{TN}{TN+FP}}{2} \quad (9)$$

اگر مجموعه داده کاملاً متعادل باشد- یعنی کلاس‌ها تقریباً یک اندازه باشند- صحت و صحت متعادل تمایل دارند به یک مقدار همگرا شوند. در واقع، تفاوت اصلی بین صحت متعادل و صحت، زمانی ظاهر می‌شود که مجموعه اولیه داده‌ها توزیع نامتعادلی را برای کلاس‌ها نشان دهد [۲۱]. مطابق با جدول ۳، صحت متعادل به دست آمده از دو طبقه‌بند KNN و SVM در روش پیشنهادی نسبت به سایر روش‌ها بهبود قابل ملاحظه‌ای داشته است. در این میان صحت متعادل به دست آمده از روش H-SMOTE برای مجموعه داده Page-blocks با اختلاف اندکی حدود ۰,۰۴۸ برای KNN و ۰,۱۱۵ برای SVM نسبت به روش پیشنهادی بیشتر است؛ اما همچنان صحت متعادل روش پیشنهادی نسبت به روش LoRAS برای مجموعه داده Page-blocks در هر دو طبقه‌بند بیشتر است.

یکی دیگر از معیارهای سنجش کارایی طبقه‌بندی مجموعه داده‌های نامتوازن، ویژگی است. معیار ویژگی به میزان توانایی یک طبقه‌بند برای یافتن نمونه‌های مثبت اشاره دارد. طبق (۱۰) برای به دست آوردن معیار ویژگی باید نسبت موارد منفی حقیقی را به مجموع موارد منفی حقیقی و مثبت کاذب حساب کرد

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (10)$$

جدول ۲: تنظیمات پارامترهای روش LORAS

N_{aff}	k	تعداد نمونه‌های اقلیت	مجموعه داده	
			LORAS	Page-blocks
۹	۵	۲۹	Glass	ع
۸	۳۰	۱۶۳	Yeast	۳
۱۰	۳۰	۵۵۹		Page-blocks
۷	۵	۳۵		Ecoli
۸	۵	۵۱		Yeast
۸	۵	۳۵		Yeast
۷	۵	۷	Ecoli	- ۱ - ۳ - ۷ - vs - ۲ - ۶
۸	۵	۳۲	Abalone	۱۹

از روش پیشنهادی با طبقه‌بند KNN برای مجموعه داده نامتوازن Yeast به شناسه D5 به میزان ۰,۱۲ با مقدار استاندارد توانزن فاصله داده؛ در حالی که در روش H-SMOTE حدود ۰,۵۱ با میزان توانزن استاندارد فاصله دارد.

برای ارزیابی کارایی روش پیشنهادی برای مجموعه داده‌های نامتوازن، معیار صحت متعادل^۱ طبقه‌بندی‌های KNN و SVM برای ۸ مجموعه داده‌ای نامتوازن ارزیابی گردیده است. صحت متعادل یکی از معیارهای شناخته شده در طبقه‌بندی مجموعه داده‌های نامتوازن است که بر اساس ماتریس درهم‌ریختگی^۲ (شکل ۶) و مطابق (۹) محاسبه می‌شود

1. Balanced Accuracy
2. Confusion Matrix

تمایز بین کلاس‌ها خلاصه کرد. هرچه میزان AUC بالاتر باشد، عملکرد طبقه‌بند در تشخیص کلاس‌های اقلیت و اکثربیت بهتر است. برای هر مجموعه داده، بالاترین مقدار صحت، F و AUC به دست آمده از هر طبقه‌بند در جداول ۵ و ۶ مشخص شده است.

همان طور که ذکر گردید جدول ۵ نتایج ارزیابی معیارهای صحت، F و AUC از طبقه‌بند KNN را بر روی ۸ مجموعه داده‌ای نشان می‌دهد. با توجه به نتایج ارائه شده از معیار صحت، روش پیشنهادی بر روی ۵ مجموعه داده‌ای از ۸ مجموعه داده عملکرد بهتری نسبت به سایر روش‌ها داشته و در سه مجموعه داده Yeast^۴, Page-blocks^۰, Abalone^{۱۹} و H-SMOTE بهترین با اختلاف اندک ۰,۰۰۰۳ و ۰,۰۰۰۲۵ و ۰,۰۰۰۵۲ روش H-SMOTE معیار صحت بهتری داشته است.

مطابق با نتایج بدست آمده از معیار F , روش پیشنهادی در اکثر مجموعه داده‌ها بهتر عمل کرده است و فقط در مجموعه داده‌ای Page-blocks^۰ H-SMOTE روش H-SMOTE با اختلاف ۰,۰۰۰۵ با اختلاف ۰,۰۰۰۵ کارایی بیشتری داشته است. به همین ترتیب نتایج روش پیشنهادی بر اساس معیار AUC در اکثر مجموعه داده‌ها حکایت از عملکرد بهتر دارد؛ به غیر از H-SMOTE مجموعه داده Page-blocks^۰ با اختلاف ۰,۰۰۰۴۸ روش H-SMOTE از نتیجه بهتری برخوردار بوده است.

مطابق با جدول ۶ با توجه به نتایج ارائه شده از طبقه‌بند SVM, روش پیشنهادی بر اساس معیار صحت در ۵ مجموعه داده از ۸ مجموعه نتیجه بهتری را نشان می‌دهد؛ به جز سه مجموعه داده Page-blocks^۰, Abalone^{۱۹} و Yeast^۴ که با روش H-SMOTE صحت بالاتر داشتند. معیار F روش پیشنهادی در اکثر مجموعه داده‌ها بالاتر است؛ به غیر از H-SMOTE و Page-blocks^۰ Abalone^{۱۹} که به ترتیب روش LoRAS و روش H-SMOTE در مجموعه داده Page-blocks^۰ کارایی بیشتری داشته است.

در آزمایش دیگر برای ارزیابی اثربخشی اتوماتای یادگیر در انتخاب نمونه، روش مبتنی بر اتوماتای یادگیر با روش حذف تصادفی مقایسه شده است. در روش حذف تصادفی، پس از مرحله داده‌افزایی با H-SMOTE و LoRAS برای ایجاد تعادل در اندازه کلاس اقلیت و اکثربیت، نمونه‌های کلاس C'_{\min} به صورت کاملاً تصادفی حذف می‌شوند. در جداول ۷ و ۸ کارایی اتوماتای یادگیر و روش حذف تصادفی برای دو طبقه‌بند KNN و SVM مقایسه شده است. همان طور که مشاهده می‌گردد روش مبتنی بر اتوماتای یادگیر در تمامی مجموعه داده‌ها و برای هر دو طبقه‌بند KNN و SVM از صحت، F و AUC بالاتری برخوردار است. دلیل این امر، به کارگیری اتوماتای یادگیر برای شناسایی و حذف نمونه‌هایی است که تأثیر کمتری در طبقه‌بندی دارند. به بیانی دیگر، حذف تصادفی نمونه‌ها ممکن است منجر به حذف نمونه‌های اصلی و مؤثر در طبقه‌بندی و به تبع آن، کاهش کارایی طبقه‌بندی شود.

به طور خلاصه نتایج آزمایش‌های انجام گرفته نشان می‌دهند که روش پیشنهادی برای معادل‌سازی مجموعه داده‌ای نامتوانز در هر دو طبقه‌بند KNN و SVM در اکثر مجموعه داده‌ای نامتوانز مورد مطالعه، عملکرد بهتری را در مقایسه با روش‌های H-SMOTE و LoRAS دارد. بر اساس نتایج بدست آمده برای روش پیشنهادی می‌توان اظهار کرد که برای طبقه‌بندی نمونه‌های مجموعه داده‌ای نامتوانز به هر دو کلاس اقلیت و اکثربیت، اهمیت یکسان داده می‌شود.

		برچسب پیش‌بینی شده	
کلاس‌ها		Positive (+)	Negative (-)
برچسب واقعی	Positive (+)	<i>TP</i>	<i>FN</i>
	Negative (-)	<i>FP</i>	<i>TN</i>

شكل ۶: ماتریس درهم‌ریختگی.

در جدول ۴، نتایج ارزیابی طبقه‌بندهای KNN و SVM برای مجموعه داده‌های نامتوانز بر اساس معیار ویژگی آمده است. بر اساس معیار ویژگی در اکثر مجموعه داده‌ها روش پیشنهادی به نتیجه بهتری نسبت به سایر روش‌ها دست یافته است. در مجموعه داده‌ای Page-blocks^۰، معیار ویژگی روش H-SMOTE با اختلاف حدود ۰,۰۰۰۹۸ برای KNN و ۰,۰۰۱۲۴ برای SVM نتیجه بهتری را داشته است؛ اما همان طور که ملاحظه می‌شود معیار ویژگی روش پیشنهادی برای این مجموعه نسبت به روش LoRAS بیشتر است. در مجموعه داده‌ای Yeast^۴ معیار ویژگی در روش LoRAS با طبقه‌بند SVM با اختلاف ۰,۰۳۳۵ نسبت به روش پیشنهادی بیشتر می‌باشد و در مجموعه داده‌ای Abalone^{۱۹} با طبقه‌بند LoRAS روش SVM و با طبقه‌بند H-SMOTE بهتری داشته است.

برای ارزیابی عملکرد طبقه‌بندهای در نظر گرفته شده، سایر معیارهای ارزیابی استاندارد مانند صحت، معیار F و AUC نیز اندازه‌گیری شدند. این معیارهای ارزیابی بر اساس ماتریس درهم‌ریختگی که در شکل ۶ نشان داده شده است، محاسبه می‌گردند. صحت یک طبقه‌بند نشان می‌دهد که چه میزان از نمونه‌های پیش‌بینی شده با برچسب واقعی کلاس مطابقت دارند. برای محاسبه صحت از (۱۱) استفاده می‌شود

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (11)$$

معیار F بر اساس معیارهای دقت و فراخوانی محاسبه می‌شود؛ بنابراین به طور خلاصه به مفهوم معیارهای دقت و فراخوانی می‌پردازیم. معیار دقت برای یک طبقه‌بند با توجه به یک کلاس خاص، نسبت تعداد نمونه‌های بهدرستی پیش‌بینی شده به تعداد کل نمونه‌های آن کلاس است. فراخوانی برای یک کلاس خاص، نسبت نمونه‌هایی است که بهدرستی پیش‌بینی شده‌اند به تعداد کل نمونه‌هایی که واقعاً متعلق به کلاس هستند. معیارهای دقت و فراخوانی بهترین ترتیب بر اساس (۱۲) و (۱۳) تعریف می‌شوند

$$precision = \frac{TP}{TP + FP} \quad (12)$$

$$recall = \frac{TP}{TP + FN} \quad (13)$$

معیار F نیز میانگین هارمونیک دقت و فراخوانی است که مطابق (۱۴) اندازه‌گیری می‌شود

$$F = \frac{2 \times precision \times recall}{precision + recall} \quad (14)$$

منحنی (ROC) معیاری برای ارزیابی مسائل طبقه‌بندی دودویی است. ROC یک منحنی احتمال است که TPR را در برابر FPR در آستانه‌های متفاوت ترسیم می‌کند. منحنی ROC را می‌توان با استفاده از مساحت زیر منحنی (AUC) برای تشخیص میزان توانایی طبقه‌بند برای

1. False Positive Rate

جدول ۳: نتایج ارزیابی طبقه‌بندهای KNN و SVM بر اساس معیار صحت متعادل.

روش پیشنهادی		LoRAS		H-SMOTE		مجموعه داده
KNN	SVM	KNN	SVM	KNN	SVM	
۰.۹۸۰۷	۰.۹۸۹۷	۰.۹۴۴۲	۰.۹۶۲۷	۰.۹۶۰۰	۰.۹۷۷۵	Glass ^۶
۰.۹۸۴۱	۰.۹۶۸۹	۰.۹۷۶۷	۰.۹۵۸۵	۰.۹۷۸۶	۰.۹۴۸۱	Yeast ^۳
۰.۹۷۵۱	۰.۹۶۶۵	۰.۹۵۲۱	۰.۹۴۵۲	۰.۹۷۹۹	۰.۹۷۸۰	Page-blocks [*]
۰.۹۷۷۸	۰.۹۵۵۱	۰.۹۶۲۴	۰.۹۱۶۸	۰.۹۴۸۲	۰.۹۱۵۶	Ecoli ^۳
۰.۹۶۲۵	۰.۹۳۷۳	۰.۹۴۴۹	۰.۸۹۳۷	۰.۹۵۶۲	۰.۹۱۹۹	Yeast ^۴
۰.۹۸۷۱	۰.۹۷۲۶	۰.۹۷۳۹	۰.۹۴۹۰	۰.۹۷۸۵	۰.۹۵۱۴	Yeast ^۶
۰.۹۹۳۵	۰.۹۸۸۵	۰.۹۶۳۴	۰.۹۱۰۶	۰.۹۸۸۵	۰.۹۷۱۲	Ecoli [*] - ۱ - ۳ - ۷ - vs - ۲ - ۶
۰.۹۹۲۵	۰.۹۱۷۰	۰.۹۷۷۵	۰.۹۰۹۰	۰.۹۹۲۲	۰.۹۰۲۰	Abalone ^{۱۹}

جدول ۴: نتایج ارزیابی طبقه‌بندهای KNN و SVM بر اساس معیار ویژگی.

روش پیشنهادی		LoRAS		H-SMOTE		مجموعه داده
KNN	SVM	KNN	SVM	KNN	SVM	
۱	۱	۰.۹۲۸۵	۰.۹۸۴۳	۰.۹۳۲۲	۰.۹۶۷۷	Glass ^۶
۰.۹۷۶۹	۰.۹۴۰۱	۰.۹۶۹۳	۰.۹۳۷۱	۰.۹۶۶۸	۰.۹۰۱۸	Yeast ^۳
۰.۹۶۵۰	۰.۹۵۷۷	۰.۹۴۸۶	۰.۹۳۹۵	۰.۹۷۴۸	۰.۹۷۰۱	Page-blocks [*]
۰.۹۶۵۵	۰.۹۲۰۴	۰.۹۲۴۷	۰.۸۵۸۶	۰.۸۹۶۵	۰.۸۳۹۰	Ecoli ^۳
۰.۹۳۱۲	۰.۸۹۴۷	۰.۹۲۲۸	۰.۹۲۸۲	۰.۹۱۹۵	۰.۸۴۵۷	Yeast ^۴
۰.۹۷۶۶	۰.۹۴۹۳	۰.۹۵۷۱	۰.۹۴۶۱	۰.۹۵۹۴	۰.۹۰۹۷	Yeast ^۶
۱	۰.۹۷۷۰	۰.۹۲۶۸	۰.۸۸۳۷	۰.۹۷۷۰	۰.۹۶۲۵	Ecoli [*] - ۱ - ۳ - ۷ - vs - ۲ - ۶
۰.۹۸۸۴	۰.۸۴۱۲	۰.۹۷۱۸	۰.۸۶۹۸	۰.۹۹۱۲	۰.۸۰۵۲	Abalone ^{۱۹}

جدول ۵: نتایج ارزیابی طبقه‌بند KNN بر اساس معیارهای صحت، F و AUC.

روش پیشنهادی		LoRAS		H-SMOTE		مجموعه داده
AUC	F	صحت	AUC	F	صحت	
۰.۹۸۰۷	۰.۹۸۲۷	۰.۹۸۱۶	۰.۹۴۴۲	۰.۹۵۴۱	۰.۹۳۸۲	۰.۹۶۴۵
۰.۹۸۴۱	۰.۹۸۳۲	۰.۹۸۴۶	۰.۹۷۶۷	۰.۹۸۶	۰.۹۷۴۲	Yeast ^۳
۰.۹۷۵۱	۰.۹۷۲۷	۰.۹۷۶۳	۰.۹۵۲۱	۰.۹۶۶۳	۰.۹۵۰۸	۰.۹۷۳۲
۰.۹۷۷۸	۰.۹۷۶۷	۰.۹۷۸۸	۰.۹۶۲۴	۰.۹۶۰۸	۰.۹۴۶۹	۰.۹۴۵۴
۰.۹۶۲۵	۰.۹۶۰۷	۰.۹۶۵۴	۰.۹۴۴۹	۰.۹۵۲۹	۰.۹۳۶۰	۰.۹۵۱۲
۰.۹۸۷۱	۰.۹۸۷۰	۰.۹۸۷۲	۰.۹۷۳۹	۰.۹۷۵۷	۰.۹۶۸۵	۰.۹۷۶۳
۰.۹۹۳۵	۰.۹۹۳۴	۰.۹۹۳۷	۰.۹۶۳۴	۰.۹۶۲۹	۰.۹۴۹۱	۰.۹۸۸۰
۰.۹۹۲۵	۰.۹۹۲۶	۰.۹۹۲۳	۰.۹۷۷۵	۰.۹۸۲۲	۰.۹۷۵۵	Ecoli [*] - ۱ - ۳ - ۷ - vs - ۲ - ۶
						Abalone ^{۱۹}

جدول ۶: نتایج ارزیابی طبقه‌بند SVM بر اساس معیارهای صحت، F و AUC.

روش پیشنهادی		LoRAS		H-SMOTE		مجموعه داده
AUC	F	صحت	AUC	F	صحت	
۰.۹۸۹۷	۰.۹۹۱۳	۰.۹۹۰۵	۰.۹۶۲۷	۰.۹۸۴۳	۰.۹۷۵۳	۰.۹۷۵۶
۰.۹۶۸۹	۰.۹۶۷۷	۰.۹۷۲۹	۰.۹۵۸۵	۰.۹۶۴۳	۰.۹۵۱۸	Yeast ^۳
۰.۹۶۶۵	۰.۹۶۴۹	۰.۹۶۶۹	۰.۹۴۵۲	۰.۹۵۹۲	۰.۹۳۹۵	۰.۹۷۸۰
۰.۹۵۵۱	۰.۹۵۲۹	۰.۹۵۶۹	۰.۹۱۸۶	۰.۹۱۸۶	۰.۹۱۵۶	۰.۹۰۶۸
۰.۹۳۷۳	۰.۹۳۲۰	۰.۹۴۲۳	۰.۸۹۷۷	۰.۹۲۶۵	۰.۹۰۴۹	۰.۹۱۹۹
۰.۹۷۲۶	۰.۹۷۱۸	۰.۹۷۳۹	۰.۹۴۹۰	۰.۹۶۰۷	۰.۹۴۸۰	۰.۹۵۱۴
۰.۹۸۸۵	۰.۹۸۶۳	۰.۹۸۷۸	۰.۹۱۰۶	۰.۹۲۶۸	۰.۸۹۸۳	۰.۹۷۱۲
۰.۹۱۷۰	۰.۹۰۹۴	۰.۹۱۸۴	۰.۹۰۹۰	۰.۹۱۸۱	۰.۸۹۵۲	۰.۹۰۲۰
						Abalone ^{۱۹}

کلاسی می‌شود که تعداد نمونه‌های کمتری دارد (کلاس اقلیت) و این در حالی است که در اغلب مسائل طبقه‌بندی این کلاس از اهمیت بیشتری برخوردار است. جهت رفع این مشکل بایست به معادل نمودن این گونه عدم توازن کلاس‌ها در مجموعه داده‌ها باعث نادیده‌گرفته شدن

۵- نتیجه‌گیری

عدم توازن کلاس‌ها در مجموعه داده‌ها باعث نادیده‌گرفته شدن

جدول ۷: مقایسه کارایی روش مبتنی بر اتوماتای یادگیر با روش حذف تصادفی برای طبقه‌بند KNN.

اتوماتای یادگیر			حذف تصادفی			مجموعه داده
AUC	F	صحت	AUC	F	صحت	
۰.۹۸۰۷	۰.۹۸۲۷	۰.۹۸۱۶	۰.۹۴۸۲	۰.۹۴۳۳	۰.۹۴۸۷	Glass ^۶
۰.۹۸۴۱	۰.۹۸۳۲	۰.۹۸۴۶	۰.۹۷۳۵	۰.۹۷۳۵	۰.۹۷۳۳	Yeast ^۳
۰.۹۷۵۱	۰.۹۷۲۷	۰.۹۷۶۳	۰.۹۶۹۲	۰.۹۶۸۹	۰.۹۶۹۲	Page-blocks [*]
۰.۹۷۷۸	۰.۹۷۶۷	۰.۹۷۸۸	۰.۹۲۲۰	۰.۹۱۵۶	۰.۹۲۶۷	Ecoli ^۳
۰.۹۶۲۵	۰.۹۶۰۷	۰.۹۶۵۴	۰.۹۴۷۲	۰.۹۴۳۰	۰.۹۵۲۸	Yeast ^۴
۰.۹۸۷۱	۰.۹۸۷۰	۰.۹۸۷۲	۰.۹۷۳۱	۰.۹۷۲۳	۰.۹۷۳۷	Yeast ^۶
۰.۹۹۳۵	۰.۹۹۳۴	۰.۹۹۳۷	۰.۹۷۲۲	۰.۹۷۱۴	۰.۹۶۹۶	Ecoli [*] - ۱-۳-۷-vs-۲-۶
۰.۹۹۲۵	۰.۹۹۲۶	۰.۹۹۲۳	۰.۹۹۰۱	۰.۹۸۹۹	۰.۹۹۰۲	Abalone ^{۱۹}

جدول ۸: مقایسه کارایی روش مبتنی بر اتوماتای یادگیر با روش حذف تصادفی برای طبقه‌بند SVM.

اتوماتای یادگیر			حذف تصادفی			مجموعه داده
AUC	F	صحت	AUC	F	صحت	
۰.۹۸۹۷	۰.۹۹۱۳	۰.۹۹۰۵	۰.۹۵۶۰	۰.۹۵۲۳	۰.۹۵۷۲	Glass ^۶
۰.۹۶۸۹	۰.۹۶۷۷	۰.۹۷۲۹	۰.۹۵۴۹	۰.۹۵۳۸	۰.۹۵۴۳	Yeast ^۳
۰.۹۶۶۵	۰.۹۶۴۹	۰.۹۶۶۹	۰.۹۶۲۳	۰.۹۶۲۷	۰.۹۶۲۴	Page-blocks [*]
۰.۹۵۵۱	۰.۹۵۲۹	۰.۹۵۶۹	۰.۹۰۴۴	۰.۸۹۴۴	۰.۹۱۰۹	Ecoli ^۳
۰.۹۳۷۳	۰.۹۳۲۰	۰.۹۴۲۳	۰.۹۲۲۵	۰.۹۱۴۰	۰.۹۲۹۳	Yeast ^۴
۰.۹۷۲۶	۰.۹۷۱۸	۰.۹۷۳۹	۰.۹۵۳۱	۰.۹۵۰۹	۰.۹۵۴۳	Yeast ^۶
۰.۹۸۸۵	۰.۹۸۶۳	۰.۹۸۷۸	۰.۹۶۶۶	۰.۹۶۵۵	۰.۹۶۳۶	Ecoli [*] - ۱-۳-۷-vs-۲-۶
۰.۹۱۷۰	۰.۹۰۹۴	۰.۹۱۸۴	۰.۹۰۷۹	۰.۸۹۹۰	۰.۹۱۰۱	Abalone ^{۱۹}

- [4] P. Kumar, R. Bhatnagar, K. Gaur, and A. Bhatnagar, "Classification of imbalanced data: review of methods and applications," *IOP Conf. Series: Materials Science and Engineering*, vol. 1099, no 1, Article ID: 012077, 2021.
- [5] C. F. Tsai, W. C. Lin, Y. H. Hu, and G. T. Yao, "Under-sampling class imbalanced datasets by combining clustering analysis and instance selection," *Information Sciences*, vol. 477, pp. 47-54, Mar. 2019.
- [6] I. Czarnowski and P. Jedrzejowicz, "An approach to imbalanced data classification based on instance selection and over-sampling," in *Proc. 11th Int. Conf. on Computational Collective Intelligence*, pp. 601-610, Hendaye, France, 4-6 Sept. 2019.
- [7] D. Gan, J. Shen, B. An, M. Xu, and N. Liu, "Integrating TANBN with cost sensitive classification algorithm for imbalanced data in medical diagnosis," *Computers & Industrial Engineering*, vol. 140, Article ID: 106266, Feb. 2020.
- [8] L. Yang and Y. Jiachen, "Meta-learning baselines and database for few-shot classification in agriculture," *Computers and Electronics in Agriculture*, vol. 182, Article ID: 106055, Mar. 2021.
- [9] Z. Peng, Z. Li, J. Zhang, Y. Li, G. J. Qi, and J. Tang, "Few-shot image recognition with knowledge transfer," in *Proc. of the IEEE/CVF Int. Conf. on Computer Vision*, pp. 441-449, Seoul, South Korea, 27 Oct.-2 Nov. 2019.
- [10] F. Jimenez, G. Sanchez, J. Palma, and G. Sciavicco, "Three-objective constrained evolutionary instance selection for classification: wrapper and filter approaches," *Engineering Applications of Artificial Intelligence*, vol. 107, Article ID: 104531, Jan. 2022.
- [11] G. E. Melo-Acosta, F. Duitama-Muñoz, and J. D. Arias-Londoño, *An Instance Selection Algorithm for Big Data in High Imbalanced Datasets Based on LSH*, arXiv: 2210.04310, Oct. 2022.
- [12] X. Chao and L. Zhang, "Few-shot imbalanced classification based on data augmentation," *Multimedia Systems*, vol. 29, no. 5, pp. 2843-2851, 2023.
- [13] S. Bej, N. Davtyan, M. Wolfien, M. Nassar, and O. Wolkenhauer, "LoRas: an oversampling approach for imbalanced datasets," *Machine Learning*, vol. 110, pp. 279-301, 2021.
- [14] J. C. Requelmé, J. S. Aguilar-Ruiz, and M. Toro, "Finding representative patterns with ordered projections," *Pattern Recognition*, vol. 36, no. 4, pp. 1009-1018, Apr. 2003.

مجموعه داده‌ها پرداخت.

در این مقاله مشکل عدم توازن این گونه مجموعه داده‌ها، بررسی و در این راستا، روشنی جدید برای معادل نمودن مجموعه داده‌ای نامتوازن پیشنهاد گردید. در روش پیشنهادی، ابتدا نمونه‌های کلاس اقلیت در هر مجموعه داده‌ای نامتوازن با دو روش LoRAS و H-SMOTE داده‌افزایی شدند و با توجه به اینکه نسبت عدم توازن مجموعه داده‌ها همچنان بالا بود، روشی ابتکاری برای رسیدن به تعادل نسبی ارائه گردید. در این روش پس از اداده‌افزایی، عمل انتخاب نمونه بر روی نمونه‌های کلاس اقلیت پیاده می‌شود. در عمل انتخاب نمونه به هر نمونه از کلاس اقلیت، یک اتوماتای یادگیر جهت انتخاب‌شدن یا نشدن در مجموعه کاهش‌یافته نهایی نسبت داده می‌شود و طبق نتیجه صحت طبقه‌بندی‌ها در اتوماتای یادگیر پاداش یا جریمه داده می‌شود. در اساس نتایج آزمایش‌های انجام گرفته در روش پیشنهادی نسبت به روش‌های LoRAS و H-SMOTE، مجموعه داده‌ها از نسبت عدم توازن مناسب‌تری برخوردار هستند. همچنان در مجموع، روش پیشنهادی بر اساس معیارهای رایج طبقه‌بندی مجموعه داده‌ای نامتوازن یعنی صحت متعادل و ویژگی در مقایسه با دو روش مذکور عملکرد بهتری داشته است.

مراجع

- [1] H. Kim, H. Cho, and D. Ryu, "Corporate bankruptcy prediction using machine learning methodologies with a focus on sequential data," *Computational Economics*, vol. 59, pp. 1231-1249, 2022.
- [2] D. Yousif Mikhail, F. Al-Mukhtar, and S. Wahab Kareem, "A comparative evaluation of cancer classification via TP53 gene mutations using machine learning," *Asian Pacific J. of Cancer Prevention*, vol. 23, no. 7, pp. 2459-2467, Jul. 2022.
- [3] L. Yang and Y. Jiachen, "Few-shot cotton pest recognition and terminal," *Computers and Electronics in Agriculture*, vol. 169, Article ID: 105240, 2020.

بررسی مدرک کارشناسی خود را در رشته مهندسی کامپیوتر گرایش فناوری اطلاعات در سال ۱۳۹۸ از دانشگاه زابل دریافت کرد و در حال حاضر دانشجوی کارشناسی ارشد در رشته مهندسی فناوری اطلاعات گرایش مدیریت سیستم‌های اطلاعاتی در دانشگاه سیستان و بلوچستان است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از مدیریت سیستم‌های اطلاعاتی، علم داده، یادگیری ماشین و طبقه‌بندی.

سپهیا توفرستی تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی کامپیوتر به ترتیب در سال‌های ۱۳۸۲ و ۱۳۸۴ از دانشگاه صنعتی شریف و دانشگاه صنعتی امیرکبیر و در مقطع دکتری مهندسی کامپیوتر در سال ۱۳۹۴ از دانشگاه شهید بهشتی به پایان رساند و هم‌اکنون استادیار دانشکده مهندسی برق و کامپیوتر دانشگاه سیستان و بلوچستان است. زمینه‌های تحقیقاتی اصلی مورد علاقه ایشان عبارتند از هوش مصنوعی، پردازش زبان طبیعی، متن کاوی و تحلیل احساسات.

مهربی رجایی در سال ۱۳۸۲ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه صنعتی شریف و در سال ۱۳۸۴ مدرک کارشناسی ارشد مهندسی کامپیوتر خود را از دانشگاه صنعتی امیرکبیر دریافت نمود. در سال ۱۳۹۴ موفق به اخذ درجه دکترا در رشته مهندسی کامپیوتر از دانشگاه علم و صنعت شد. وی از سال ۱۳۸۴ در دانشکده مهندسی برق و کامپیوتر دانشگاه سیستان و بلوچستان مشغول به فعالیت گردید و اینک نیز عضو هیأت علمی این دانشکده است. زمینه‌های علمی مورد علاقه نامبرده شامل شبکه‌های اجتماعی، حفظ حریم خصوصی در انتشار شبکه‌های اجتماعی، پایگاه داده و محاسبات نرم است.

- [15] D. R. Wilson and T. R. Martinez, "Instance pruning techniques," in *Proc. of the 14th Int. Conf. on Machine Learning*, pp. 400-411, 8-12 Jul. 1997.
- [16] M. Moran, T. Cohen, Y. Ben-Zion, and G. Gordon, "Curious instance selection," *Information Sciences*, vol. 608, pp. 794-808, Aug. 2022.
- [17] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: synthetic minority over-sampling technique," *J. of Artificial Intelligence Research*, vol. 16, pp. 321-357, Jan. 2002.
- [۱۸] ش. سرگلزاری، ف. حسینزاده سلحوتی و ه. آقایاری، "ارائه روشهای نوین برای رتبه‌بندی اعداد فازی با استفاده از مرکز محیطی دایره و کاربرد آن در ارزیابی عملکرد مدیریت زنجیره تأمین،" *نشریه تصمیم‌گیری و تحقیق در عملیات*، دوره ۳، شماره ۳، صص. ۲۳۶-۲۴۸، پاییز ۱۳۹۷.
- [19] S. N. Kumpati and A. T. Mandayam, *Learning Automata: An Introduction*, Courier Corporation, 2012.
- [20] J. C. Dominguez, et al., "Teaching chemical engineering using Jupyter notebook: problem generators and lecturing tools," *Education for Chemical Engineers*, vol. 37, pp. 1-10, Oct. 2021.
- [21] M. Grandini, E. Bagli, and G. Visani, *Multi-Class Classification: An Overview*, arXiv:2008.05756, Aug. 2020.