



یک روش یادگیری بدون نظارت برای تشخیص الگوهای غیرمعمول و ناهنجاری در داده‌های تراکنشی

سارا نجفی

دانشجوی کارشناسی ارشد هوش مصنوعی دانشگاه آزاد واحد الکترونیکی
sara.njf.ch@gmail.com

دکتر مریم تعجبیان

استادیار مهندسی کامپیوتر دانشگاه آزاد واحد مهدی شهر
taajobian@msh-iau.ac.ir

دکتر سابینا نوبری

مدرس دانشگاه آزاد واحد الکترونیکی
Sabinamirzaei@gmail.com

چکیده

در عصر داده‌محور کنونی، تشخیص ناهنجاری در داده‌های تراکنشی نقش حیاتی در شناسایی رفتارهای غیرعادی، کشف تقلب، و ارتقاء امنیت سامانه‌های مالی و تجاری ایفا می‌کند. با توجه به ماهیت پیچیده و پویا بودن تراکنش‌ها، استفاده از روش‌های یادگیری بدون نظارت به‌عنوان رویکردی مؤثر برای کشف الگوهای غیرمعمول بدون نیاز به برچسب‌گذاری دستی، اهمیت فزاینده‌ای یافته است. در این پژوهش، یک چارچوب نوین مبتنی بر یادگیری بدون نظارت برای شناسایی ناهنجاری‌ها در داده‌های تراکنشی ارائه شده است. الگوریتم‌های متنوعی از جمله جنگل جداسازی (Isolation Forest)، ماشین بردار پشتیبان یک‌کلاسه (One-Class SVM) و عامل دورافتاده محلی (Local Outlier Factor) به‌کار گرفته شده‌اند تا رفتارهای غیرعادی در داده‌های واقعی شناسایی شوند. داده‌ها پس از پیش‌پردازش و نرمال‌سازی، با استفاده از معیارهای ارزیابی مانند نرخ کشف ناهنجاری، دقت و F_1 -Score مورد تحلیل قرار گرفته‌اند. نتایج تجربی نشان می‌دهد که روش ترکیبی، توان بالایی (دقت ۹۹.۶٪) در شناسایی الگوهای ناهنجار در داده‌های تراکنشی دارد. این چارچوب می‌تواند به‌عنوان پایه‌ای برای توسعه سیستم‌های هوشمند کشف تقلب و تحلیل رفتاری در حوزه‌های مالی، بانکی و تجارت الکترونیک مورد استفاده قرار گیرد.

کلمات کلیدی:

واژگان کلیدی: روش یادگیری بدون نظارت، تشخیص الگوهای غیرمعمول، ناهنجاری، داده‌های تراکنشی، جنگل جداسازی.

مقدمه

کشف ناهنجاری‌ها (Anomaly Detection) در داده‌های تراکنشی یکی از موضوعات مهم و حیاتی در حوزه‌های مالی، امنیتی و تجاری است. این فرآیند به شناسایی رفتارها یا الگوهای می‌پردازد که به طور قابل توجهی با رفتار عادی سیستم یا کاربران تفاوت دارند. اهمیت و ضرورت کشف ناهنجاری‌ها در داده‌های تراکنشی را می‌توان از جنبه‌های مختلفی بررسی کرد: جلوگیری از تقلب و کلاهبرداری مالی، افزایش امنیت سیستم‌ها و داده‌ها، بهبود تجربه کاربری، بهینه‌سازی فرآیندها و کاهش هزینه‌ها، انطباق با قوانین و مقررات، شناسایی فرصت‌های جدید، مقابله با فعالیت‌های غیرقانونی، افزایش دقت و کارایی سیستم‌ها (Bajpai, A. D. (2024)). با توجه به توضیحات بالا، می‌توان کشف ناهنجاری‌ها در داده‌های تراکنشی از جنبه‌های مختلفی حائز اهمیت است، از جمله جلوگیری از تقلب، افزایش امنیت، بهبود تجربه کاربری، بهینه‌سازی فرآیندها و انطباق با قوانین. این فرآیند نه تنها به کاهش هزینه‌ها و خسارات مالی کمک می‌کند، بلکه می‌تواند به شناسایی فرصت‌های جدید و بهبود استراتژی‌های تجاری نیز منجر شود. با توجه به افزایش حجم و پیچیدگی داده‌های تراکنشی، استفاده از روش‌های پیشرفته یادگیری ماشین و تحلیل داده‌ها برای تشخیص ناهنجاری‌ها ضروری است. لذا در این تحقیق یک روش نوین با استفاده از ترکیب پنج الگوریتم یادگیری ماشین برای شناسایی سریع‌تر ناهنجاری در داده‌های تراکنشی پیشنهاد خواهیم کرد.

این مقاله در پنج بخش تنظیم شده است. در بخش دوم مروری بر تحقیقات انجام شده توسط محققان دیگر خواهیم داشت. در بخش سوم روش پیشنهادی را توضیح خواهیم داد. در بخش چهارم نتایج بدست آمده از پیاده سازی روش پیشنهادی و ارزیابی کارایی روش پیشنهادی را خواهیم داشت و در نهایت نتیجه گیری و محدودیت های تحقیق را خواهیم آورد.

پیشینه تحقیق

Bolton و همکارانش (Bolton, R. J. (2021)) به کشف تقلب رفتاری از طریق تجزیه و تحلیل داده های طولی پرداختند. این داده‌ها معمولاً از تراکنش‌های کارت اعتباری در طول زمان تشکیل می‌شوند، اما می‌توانند متغیرهای دیگری، هم ثابت و هم طولی را شامل شوند. آنها در این مقاله دو روش (آماري و روشهای بدون نظارت) را برای کشف تقلب بدون نظارت در داده‌های اعتباری مورد بحث قرار دادند و آن‌ها را برای برخی از مجموعه‌های داده واقعی اعمال کردند. برای پرداختن به ریسک نمونه‌گیری و ناکارآمدی حسابرسی مالی، Bakumenko و همکارانش (Bakumenko, A. a. (2022)). از هفت تکنیک ML نظارت شده شامل یادگیری عمیق و دو تکنیک ML بدون نظارت مانند جنگل جداسازی و رمزگذار خودکار استفاده کردند. آنها مدل‌های خود را بر روی یک مجموعه داده واقعی GL آموزش و ارزیابی کردند و از بردارسازی داده‌ها برای حل تنوع اندازه ورودی مجله استفاده کردند. نتایج ارزیابی نشان داد که بهترین مدل‌های تحت نظارت و بدون نظارت آموزش‌دیده، پتانسیل بالایی در تشخیص انواع ناهنجاری از پیش تعریف‌شده و همچنین در نمونه‌برداری کارآمد از داده‌ها برای تشخیص ورودی‌های مجله با ریسک بالاتر دارند. Gogoi و همکارانش (Gogoi, P. (2020)). بر روی ANIDS های موجود را بر اساس نوع، کلاس، ماهیت شناسایی/پردازش، سطح امنیت، و غیره دسته بندی کردند. همچنین برخی از اقدامات نزدیکی را برای تجزیه و تحلیل و تشخیص داده های نفوذ به کار گرفتند. آنها همچنین برخی از نتایج تجربی را برای شناسایی حملات بر روی مجموعه داده 'KDD'99 گزارش نمودند. Schlör و همکارانش (Schlör, D. (2022)) تکنیک‌های مختلف یادگیری نمایش را برای تبدیل داده‌های تراکنش طبقه‌ای به بردارهای عددی مترکم بررسی کردند. آنها این رویکرد را با پیشنهاد گسسته‌سازی آگاهانه دورتر گسترش دادند. در مرحله بعد، سناریوهای مختلف را برای تشخیص ناهنجاری در داده‌های تراکنش ارزیابی نمودند. آنها معماری inALU خود را به یک لایه عصبی گسترش دادند که می‌تواند وابستگی‌های عددی و غیرعددی را مدل‌سازی کند و آن را در یک محیط نظارت شده و یک کلاس ارزیابی کند. در ادامه ثبات و قابلیت تعمیم رویکرد خود را بررسی کردند و نشان دادند که عملکرد آن از انواع مدل‌ها در تنظیمات نظارت‌شده متعادل و عملکرد قابل‌مقایسه‌ای در

تنظیمات یک کلاسه بهتر است. در نهایت، آنها سه رویکرد برای استفاده از یک مدل تولیدی به عنوان آشکارساز ناهنجاری را ارزیابی نمودند و عملکرد تشخیص ناهنجاری را مقایسه کردند. Munir و همکارانش (Munir, M. e. (2018).) یک رویکرد جدید تشخیص ناهنجاری مبتنی بر یادگیری عمیق (DeepAnT) برای داده‌های سری زمانی ارائه کردند که به همان اندازه برای موارد غیر جریانی قابل اجرا است. DeepAnT قادر به تشخیص طیف گسترده‌ای از ناهنجاری‌ها، به عنوان مثال، ناهنجاری‌های نقطه، ناهنجاری‌های متنی، و اختلاف در داده‌های سری زمانی است. برخلاف روش‌های تشخیص ناهنجاری که در آن ناهنجاری‌ها آموخته می‌شوند، DeepAnT از داده‌های بدون برچسب برای ضبط و یادگیری توزیع داده استفاده می‌کند که برای پیش‌بینی رفتار عادی یک سری زمانی استفاده می‌شود. Cholevas و همکارانش (Cholevas, C. e. (2024)) تکنیک‌های تشخیص ناهنجاری در اکوسیستم‌های بلاک چین را از طریق دریچه یادگیری بدون نظارت، کاوش در پیچیدگی‌ها و گذر از مجموعه پیچیده رفتارهای غیرعادی با بررسی الگوریتم‌های آوانگارد برای تشخیص انحراف از الگوهای عادی بررسی کردند. آنها پیشنهاد کردند که استفاده از الگوریتم‌های نظارت‌نشده در تشخیص ناهنجاری بلاک چین نه تنها باید به عنوان یک رویه پیاده‌سازی، بلکه به عنوان یک رویه یکپارچه‌سازی در نظر گرفته شود، به طوری که مزایای این الگوریتم‌ها را می‌توان به طور مؤثری به روش‌هایی که با مشکل در دست تعیین می‌شود ترکیب کرد. این مقاله همچنین ارائه عمیقی از ساختارهای داده‌ای را ارائه می‌دهد که معمولاً در تشخیص ناهنجاری بلاک چین مبتنی بر یادگیری بدون نظارت استفاده می‌شود. Ball و همکارانش (Ball, R. S. (2023.)) یک چارچوب مبتنی بر یادگیری ماشین برای تشخیص ناهنجاری پیشنهاد کردند که هدف آن ترکیب چندین رویکرد یادگیری ماشین برای تشخیص ناهنجاری‌ها در سیستم‌های تراکنش است. چارچوب پیشنهادی شامل یک رویکرد واحد برای ترکیب جنبه‌های فرآیند تشخیص ناهنجاری در یک خط لوله منفرد است. این رویکرد با جستجوی معماری عصبی آغاز می‌شود، که در آن چندین معماری رمزگذار خودکار کاندید به طور تصادفی شبیه‌سازی می‌شوند تا یک پیکربندی معماری بهینه را تعیین کنند. چارچوب پیشنهادی نهایی در یک محیط واقعی برای نشان دادن کاربرد عملی اجرا شد. نتایج به دست آمده از پیاده‌سازی با موفقیت به هدف اصلی، که بهبود تشخیص ناهنجاری‌ها در یک محیط معاملاتی بود، دست یافت. Huang و همکارانش (Huang, D. e. (2018).) یک چارچوب جدید کشف تقلب به نام CoDetect را پیشنهاد کردند که می‌تواند هم اطلاعات شبکه و هم اطلاعات ویژگی را برای تشخیص تقلب مالی اعمال کند. علاوه بر این، CoDetect می‌تواند به طور همزمان فعالیت‌های کلاهبرداری مالی و الگوهای ویژگی‌های مرتبط با فعالیت‌های کلاهبرداری را شناسایی کند. Carcillo و همکارانش (Carcillo, F. e. (2021).) یک تکنیک ترکیبی را ارائه کردند که تکنیک‌های نظارت شده و بدون نظارت را برای بهبود دقت تشخیص تقلب ترکیب می‌کند. امتیازات پرت بدون نظارت، محاسبه شده در سطوح مختلف جزئیات، با یک مجموعه داده کشف تقلب کارت اعتباری واقعی، حاشیه نویسی شده مقایسه و آزمایش می‌شوند. نتایج تجربی نشان می‌دهد که این ترکیب کارآمد است و در واقع دقت تشخیص را بهبود می‌بخشد.

روش پیشنهادی

شکل ۱ چارچوب کلی روش پیشنهادی نشان داده شده است که در آن، مراحل مختلف از پیش‌پردازش تا تشخیص ناهنجاری با ترکیب تطبیقی الگوریتم‌های SVM، SGD-SVM و Isolation Forest، LOF به صورت تصویری نمایش داده شده است. به عنوان هدف اصلی طراحی این چارچوب می‌توان گفت، ترکیب چند الگوریتم بدون نظارت (مثل LOF، Isolation Forest، One-Class SVM و SVM) صورت تطبیقی، یعنی وزن هر الگوریتم بر اساس عملکردش روی داده‌ها تنظیم شود. یعنی به جای استفاده مستقل از الگوریتم‌هایی مثل LOF یا Forest، یک چارچوب تطبیقی طراحی می‌کنیم که بسته به نوع داده، وزن هر الگوریتم تنظیم شود. این کار باعث افزایش دقت و کاهش نرخ خطا شده و نوآوری محسوب می‌شود چون کمتر کسی از ensemble در یادگیری بدون نظارت استفاده کرده است



شکل ۱- چارچوب کلی روش پیشنهادی

در ادامه هر یک از مراحل موجود در روش پیشنهادی را توضیح می دهیم.

• مرحله جمع آوری داده ها

جمع آوری داده ها یکی از مراحل بنیادین در هر پژوهش علمی محسوب می شود، زیرا کیفیت و ساختار داده ها تأثیر مستقیمی بر اعتبار نتایج نهایی دارد. در این پژوهش، داده ها از پایگاه داده KDD Cup ۱۹۹۹ استخراج شده اند که یکی از معتبرترین مجموعه داده ها در حوزه تشخیص نفوذ و ناهنجاری در شبکه های کامپیوتری است. این پایگاه داده شامل میلیون ها رکورد تراکنشی است که هر رکورد نمایانگر یک اتصال شبکه با ویژگی هایی مانند مدت زمان، نوع پروتکل، تعداد بایت های ارسال شده، وضعیت اتصال و غیره می باشد. داده های KDD به صورت خام شامل نمونه های عادی و ناهنجار هستند که در قالب چندین کلاس مختلف دسته بندی شده اند. برای اهداف این پژوهش، تنها از ویژگی های عددی استفاده شده و نمونه های ناهنجار به صورت یک کلاس مجزا در نظر گرفته شده اند. همچنین، به منظور کاهش حجم داده ها و افزایش کارایی مدل، از یک زیرمجموعه متوازن از داده ها استفاده شده است که شامل تعداد مساوی از نمونه های عادی و ناهنجار می باشد.

در مرحله جمع آوری، توجه ویژه ای به موارد زیر شده است:

- ✓ انتخاب داده هایی با تنوع بالا در ویژگی ها برای افزایش قابلیت تعمیم مدل.
- ✓ حذف داده های تکراری یا ناسازگار که ممکن است باعث بایاس در نتایج شوند.
- ✓ بررسی ساختار داده ها از نظر توزیع آماری، همبستگی بین ویژگی ها و وجود نقاط پرت.



هدف از این مرحله، فراهم سازی بستری مناسب برای اجرای الگوریتم های یادگیری ماشین و اطمینان از کیفیت داده های ورودی است.

• پیش پردازش داده ها

پیش پردازش داده ها مرحله ای حیاتی در آماده سازی داده ها برای تحلیل و مدل سازی است. داده های خام معمولاً شامل نویز، مقادیر گمشده، مقیاس های متفاوت و ویژگی های نامرتب هستند که می توانند عملکرد مدل را به شدت تحت تأثیر قرار دهند. در این پژوهش، مراحل پیش پردازش با دقت و بر اساس اصول علمی زیر انجام شده اند:

• پاک سازی داده ها

در این مرحله، نمونه هایی که دارای مقادیر گمشده، نامعتبر یا خارج از دامنه منطقی بودند، حذف شدند. همچنین، داده های تکراری شناسایی و حذف گردیدند تا از بایاس آماری جلوگیری شود.

• نرمال سازی ویژگی ها

با توجه به اینکه الگوریتم های یادگیری ماشین نسبت به مقیاس ویژگی ها حساس هستند، تمامی ویژگی های عددی با استفاده از روش Min-Max Scaling به بازه [۰,۱] نگاشت شدند. این کار باعث می شود که ویژگی هایی با دامنه بزرگ تر تأثیر نامتناسبی بر مدل نداشته باشند (Dongqi, et al. (2021)).

• رمزگذاری ویژگی های غیر عددی

ویژگی هایی مانند نوع پروتکل یا وضعیت اتصال که به صورت متنی بودند، با استفاده از روش One-Hot Encoding به فرم عددی تبدیل شدند. این روش باعث می شود که مدل بتواند تفاوت بین مقادیر متنی را به درستی درک کند بدون اینکه ترتیب خاصی به آن ها نسبت دهد.

• انتخاب ویژگی ها

با استفاده از روش های آماری مانند تحلیل همبستگی و آزمون های اطلاعات متقابل، ویژگی هایی که تأثیر کمی بر تشخیص ناهنجاری داشتند، حذف شدند. این کار باعث کاهش پیچیدگی مدل و افزایش سرعت آموزش شد.

• تقسیم داده ها

داده ها به دو بخش آموزش (۷۰٪) و تست (۳۰٪) تقسیم شدند تا ارزیابی مدل به صورت مستقل انجام شود. این تقسیم بندی به صورت تصادفی و با حفظ نسبت نمونه های عادی و ناهنجار انجام شد. پیش پردازش دقیق داده ها نه تنها باعث افزایش دقت مدل می شود، بلکه از بروز خطاهای محاسباتی و نتایج گمراه کننده جلوگیری می کند.

مرحله اجرای الگوریتم های پایه

در این مرحله، الگوریتم های پایه ای که در چارچوب ترکیبی تطبیقی مورد استفاده قرار می گیرند، به صورت مستقل و موازی بر روی داده های پیش پردازش شده اجرا می شوند. هدف از این مرحله، استخراج نمرات ناهنجاری از دیدگاه های مختلف الگوریتمی است تا بتوان در مراحل بعدی آن ها را ترکیب و تحلیل کرد. انتخاب الگوریتم ها بر اساس معیارهایی مانند تنوع روش شناسی، قابلیت تفسیر، سرعت اجرا و عملکرد تجربی در مطالعات پیشین انجام شده است.

این مرحله نقش کلیدی در آماده سازی داده ها برای تجمیع نهایی دارد و پایه ای برای محاسبه وزن های تطبیقی فراهم می سازد.

مرحله محاسبه وزن های تطبیقی

در یک چارچوب ترکیبی، همه الگوریتم‌ها به صورت برابر عمل نمی‌کنند. برخی الگوریتم‌ها در تشخیص ناهنجاری‌ها عملکرد بهتری دارند و برخی دیگر ممکن است در شرایط خاص دچار خطا شوند. از این رو، استفاده از وزن‌های تطبیقی برای هر الگوریتم ضروری است تا تأثیر آن‌ها در خروجی نهایی متناسب با کیفیت عملکردشان تنظیم شود.

• معیارهای تعیین وزن

در این پژوهش، وزن هر الگوریتم بر اساس سه معیار اصلی تعیین شده است:

- ✓ دقت نسبی: اگر داده‌ها دارای برجستگی باشند، می‌توان عملکرد هر الگوریتم را با معیارهایی مانند Precision، Recall و F1- Score ارزیابی کرد. الگوریتم‌هایی با دقت بالاتر وزن بیشتری دریافت می‌کنند (Taejin Lee, (2020).
- ✓ همبستگی خروجی‌ها: با محاسبه ضریب همبستگی پیرسون بین نمرات ناهنجاری الگوریتم‌ها، می‌توان میزان توافق آن‌ها را سنجید. الگوریتم‌هایی که خروجی آن‌ها با سایر الگوریتم‌ها هم‌راستا باشد، قابل اعتمادتر تلقی می‌شوند.
- ✓ پایداری نمرات: با اعمال تغییرات جزئی در داده‌ها (مثلاً حذف تصادفی ۵٪ نمونه‌ها)، نمرات ناهنجاری مجدداً محاسبه می‌شوند. الگوریتم‌هایی که نمراتشان پایدار باقی بماند، وزن بیشتری دریافت می‌کنند.

• نرمال‌سازی وزن‌ها

پس از محاسبه وزن‌ها، آن‌ها به گونه‌ای نرمال‌سازی می‌شوند که مجموع وزن‌ها برابر با ۱ باشد. این کار باعث می‌شود که در مرحله جمع‌بندی نهایی، سهم هر الگوریتم به صورت نسبی و قابل مقایسه لحاظ شود. استفاده از وزن‌های تطبیقی باعث می‌شود که چارچوب ترکیبی نه تنها از تنوع الگوریتم‌ها بهره‌مند شود، بلکه به صورت هوشمندانه از الگوریتم‌های قوی‌تر بیشتر استفاده کند و تأثیر الگوریتم‌های ضعیف‌تر را کاهش دهد.

تجمیع نهایی نمرات ناهنجاری

پس از استانداردسازی نمرات و تعیین وزن‌های تطبیقی، مرحله نهایی شامل ترکیب نمرات ناهنجاری از الگوریتم‌های مختلف برای هر نمونه است. هدف از این مرحله، تولید یک نمره ترکیبی است که نمایانگر ارزیابی کلی سیستم از میزان غیرعادی بودن هر نمونه باشد. این روش باعث می‌شود که نمره نهایی هر نمونه تحت تأثیر الگوریتم‌هایی قرار گیرد که عملکرد بهتری داشته‌اند.

• تحلیل نمرات ترکیبی

پس از محاسبه نمرات نهایی، توزیع آن‌ها مورد بررسی قرار گرفت. نمودارهای چگالی، هیستوگرام و جعبه‌ای برای تحلیل پراکندگی نمرات استفاده شدند. همچنین، نقاط پرت در نمرات ترکیبی شناسایی شدند تا در مرحله بعدی به عنوان ناهنجار علامت‌گذاری شوند. تجمیع نمرات با استفاده از وزن‌های تطبیقی دارای مزایای زیر است (Ankit, et al. (2021):

- ✓ افزایش دقت تشخیص ناهنجاری‌ها
- ✓ کاهش تأثیر الگوریتم‌های ضعیف‌تر
- ✓ انعطاف‌پذیری در مواجهه با داده‌های متنوع
- ✓ قابلیت تفسیر بهتر خروجی نهایی

این مرحله نقش کلیدی در موفقیت چارچوب ترکیبی دارد و پایه‌ای برای تصمیم‌گیری نهایی در مورد ناهنجاری‌ها فراهم می‌سازد.

تشخیص ناهنجاری

پس از محاسبه نمرات نهایی برای هر نمونه، مرحله تشخیص ناهنجاری آغاز می‌شود. در این مرحله، هدف آن است که با استفاده از

نمرات ترکیبی حاصل از الگوریتم‌های مختلف، نمونه‌هایی که رفتار غیرعادی دارند شناسایی شوند. این فرآیند شامل تعیین آستانه تصمیم‌گیری، تحلیل آماری نمرات و ارزیابی عملکرد مدل است.

• تعیین آستانه (Threshold)

برای تشخیص ناهنجاری، لازم است یک آستانه عددی تعیین شود که نمرات بالاتر از آن به‌عنوان ناهنجار تلقی شوند. در این پژوهش، از روش‌های آماری برای تعیین آستانه استفاده شده است. یکی از روش‌های رایج، استفاده از صدک ۹۵ یا ۹۹ نمرات نهایی است. به عبارت دیگر، ۵٪ یا ۱٪ از نمونه‌هایی که بالاترین نمرات را دارند، به‌عنوان ناهنجار شناسایی می‌شوند. همچنین، در صورت وجود داده‌های برچسب‌خورده، می‌توان از نمودار ROC و محاسبه نقطه تعادل بین نرخ تشخیص صحیح و نرخ خطای مثبت کاذب برای تعیین آستانه بهینه استفاده کرد (Kumari, S. e. (2024)).

• تحلیل بصری ناهنجاری‌ها

برای درک بهتر نحوه تفکیک نمونه‌های عادی و ناهنجار، از روش‌های مجازی‌سازی مانند PCA و t-SNE استفاده شده است. این روش‌ها داده‌ها را به فضای دوبعدی نگاشت می‌کنند تا بتوان توزیع نمونه‌ها را مشاهده کرد. در نمودارهای حاصل، نمونه‌های ناهنجار معمولاً در حاشیه یا خارج از خوشه‌های اصلی قرار دارند.

ارزیابی عملکرد مدل

در صورت دسترسی به برچسب‌های واقعی داده‌ها، عملکرد مدل با استفاده از معیارهای زیر ارزیابی شده است (Wang, (2019)):

Accuracy: نسبت نمونه‌های ناهنجار درست شناسایی شده به کل نمونه‌های شناسایی شده به‌عنوان ناهنجار. (فرمول ۱)

فرمول ۱

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

Precision: صحت برای نقاط پرت، نسبت مشاهدات مثبت پیش‌بینی شده درست (مثبت واقعی) به کل مثبت‌های پیش‌بینی شده (مجموع مثبت‌های درست و مثبت کاذب) است (فرمول ۲).

فرمول ۲

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

Recall: نسبت نمونه‌های ناهنجار درست شناسایی شده به کل نمونه‌های واقعی ناهنجار. (فرمول ۳)

فرمول ۳

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

F1-Score میانگین هماهنگ Precision و Recall. (فرمول ۴)

فرمول ۴

$$F1 \text{ Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

نتایج حاصل از ارزیابی نشان می‌دهد که چارچوب ترکیبی تطبیقی عملکرد بهتری نسبت به الگوریتم‌های منفرد دارد و توانایی بالایی در شناسایی ناهنجاری‌ها از دیدگاه‌های مختلف دارد. در فرمولهای بالا داریم:

TP (مثبت واقعی): تعداد نقاط پرت که به درستی به عنوان نقاط پرت شناسایی شده اند.

TN (منفی های واقعی): تعداد مشاهدات عادی که به درستی به عنوان عادی شناسایی شده اند.

FP (مثبت کاذب): تعداد مشاهدات عادی که به اشتباه به عنوان نقاط پرت شناسایی شده اند.

FN (منفی کاذب): تعداد نقاط پرت که به اشتباه به عنوان مشاهدات عادی شناسایی شده اند.

تجزیه و تحلیل مقایسه ای، شامل تجزیه و تحلیل مقایسه ای مدل ها، بحث در مورد نقاط قوت و ضعف آنها در تشخیص ناهنجاری ها است. این تحلیل توسط نمایش های بصری و معیارهای آماری پشتیبانی می شود که مناسب بودن هر الگوریتم برای انواع مختلف ناهنجاری های داده را برجسته می کند.

پیاده سازی و ارزیابی کارایی روش پیشنهادی

مراحل طی شده برای پیاده سازی و ارزیابی کارایی روش پیشنهادی عبارتند از:

• جمع آوری داده ها

داده های مورد نیاز برای پیاده سازی روش پیشنهادی از پایگاه داده ۹۹KDD جمع آوری خواهد شد. پایگاه داده ۹۹KDD عمدتاً برای تشخیص نفوذ در شبکه طراحی شده است و شامل داده های مربوط به حملات سایبری و فعالیت های مشکوک در شبکه های کامپیوتری است. این مجموعه داده برای ارزیابی سیستم های تشخیص نفوذ (IDS) استفاده می شود و شامل اطلاعاتی درباره انواع حملات و ارتباطات شبکه ای است. مجموعه داده هایی مانند Bank Transaction Dataset for Fraud Detection در Kaggle وجود دارند که شامل اطلاعات تراکنش های بانکی برای تشخیص تقلب هستند. لذا از مجموع این مجموعه داده ها برای این پژوهش استفاده خواهیم کرد. مجموعه داده Bank Transaction Dataset for Fraud Detection در Kaggle شامل اطلاعات تراکنش های مالی برای تحلیل و تشخیص تقلب است. این مجموعه داده شامل ویژگی هایی مانند مقدار تراکنش، شناسه مشتری، نوع تراکنش، زمان انجام تراکنش، و وضعیت تقلبی بودن یا نبودن است. در Kaggle مجموعه داده های مختلفی برای تراکنش های بانکی موجود است. یکی از این مجموعه داده ها شامل ۱۰۰۰ تراکنش بانکی است که شامل اطلاعاتی مانند شناسه تراکنش، مبلغ، نوع تراکنش (انتقال، برداشت، واریز)، زمان انجام تراکنش، وضعیت تراکنش (موفق یا ناموفق)، پرچم تقلب، موقعیت جغرافیایی، دستگاه مورد استفاده، تأخیر شبکه و پهنای باند می شود. جدول ۱ ویژگی های موجود در مجموعه داده های جمع آوری شده را نشان می دهد.

جدول ۱- ویژگی های موجود در مجموعه داده های جمع آوری شده [۱۶]

ویژگی	توضیحات
Transaction Amount	مقدار پولی که در جریان تراکنش، توسط مشتری جابجا شده است.
Transaction Date	تاریخ انجام تراکنش



نوع تراکنش مانند خرید آنلاین، برداشت از طریق ATM، یا انتقال از طریق موبایل بانک یا اینترنت بانک و غیره.	TransactionType
نام دارنده کارت بانکی (مشتري بانک)	Card holder Name
شماره کارتی که با استفاده از آن مشتری اقدام به انجام تراکنش می کند.	Card number
آخرین مدت زمانی که شخص می تواند از کارت اعتباری استفاده کند.	Card Expire Date
نام تاجر یا شرکت تجاری که معامله در آن انجام شده است.	Merchant Name
موقعیت مکانی (آدرس، شهر، کشور) فروشنده	Merchant Location
آدرس IP مرتبط با تراکنش	IP Address
اطلاعات مربوط به دستگاه مورد استفاده برای تراکنش، مانند نوع دستگاه، سیستم عامل و مرورگر	Device Information
موقعیت جغرافیایی تراکنش بر اساس مختصات GPS یا سایر داده های مکانی	Geolocation
وضعیت تراکنش، مانند تأیید شده، رد شده یا در انتظار	Transaction Status
یک پرچم دودویی که نشان می دهد آیا تراکنش به عنوان یک تراکنش بالقوه جعلی علامت گذاری شده است یا خیر؟	Fraud Flag
کدی که دلیل علامت گذاری تراکنش به عنوان تراکنش بالقوه جعلی را نشان می دهد.	Reason Code
اطلاعات مربوط به حساب کاربری، سابقه و رفتار کاربر، مانند سن حساب، تعداد تراکنش ها و الگوهای خرج کردن	User Profile
امتیاز عددی که سطح ریسک مرتبط با تراکنش را نشان می دهد.	Risk Score
روشی که برای تأیید تراکنش استفاده می شود، مانند پین، رمز عبور یا تأیید بیومتریک	Authentication Method
زمان صرف شده برای پاسخ به تراکنش، شامل فرآیندهای مجوز و تأیید	Response Time
اطلاعات مربوط به سایر حساب های مرتبط با حساب کاربر، مانند حساب های مشترک یا کاربران مجاز	Linked Accounts
هرگونه نمونه قبلی کلاهبرداری یا فعالیت مشکوک مرتبط با کاربر یا کارت مورد استفاده در تراکنش	Previous Fraud History

برای پیاده سازی روش پیشنهادی، از کل مجموعه داده های جمع آوری شده، با استفاده از روش نمونه برداری ساده تصادفی، ۷۰ درصد از داده ها را به عنوان مجموعه داده های تمرین و ۳۰ درصد را به عنوان مجموعه داده های تست انتخاب می کنیم.

• پردازش داده ها

برای پردازش داده های تراکنش های بانکی در پایتون، مراحل زیر را طی می کنیم:

✓ بارگذاری داده ها

✓ بررسی و پاک سازی داده ها

✓ نرمال سازی و مقیاس بندی داده ها

• اجرای الگوریتم های پیشنهادی بر روی مجموعه داده ها

تشخیص موارد خارج از قاعده در داده ها (داده های پرت یا ناهنجاری ها) یکی از جنبه های مهم تحلیل داده است و روش های مختلفی برای این کار وجود دارد. برخی از رایج ترین روش ها عبارتند از (Obeng, S. e. (2024):

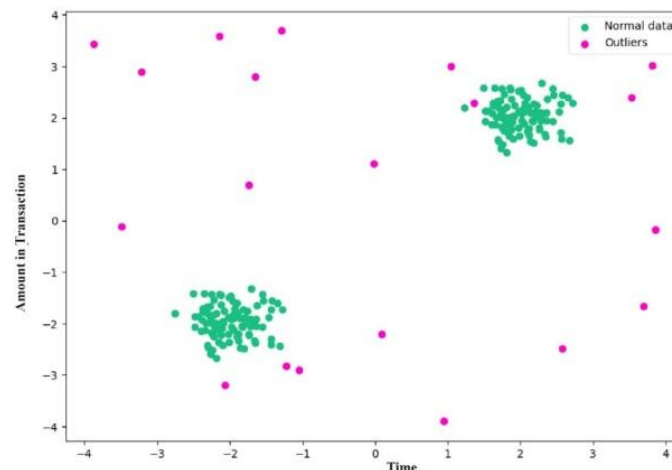
✓ روش های آماری

✓ روش های مبتنی بر یادگیری ماشین

در این تحقیق از روش های یادگیری نظارت نشده (شامل ماشین بردار ماشین یک کلاسه، SVM یک کلاسی با نزول گرادین تصادفی (SGD)، جنگل جداسازی (iForest) و عامل دورافتاده محلی (LOF)) استفاده می کنیم.

شکل ۲، یک نمودار پراکندگی داده های مورد استفاده در این پژوهش را نشان می دهد که دارای دو خوشه اصلی از داده های نرمال (نقاط سبز) و چندین نقاط پرت (صورتی) است. محورهای نمودار با عنوان میزان پول جابجا شده در تراکنشها (به عنوان ویژگی شماره ۱) و زمان انجام تراکنشها (به عنوان ویژگی شماره ۲) برچسب گذاری شده اند و مقادیر آنها بین -۴ تا ۴ متغیر است. علت اینکه مقادیر ویژگیها بین ۴- تا ۴- تنظیم شده است، این است که استانداردسازی داده ها انجام شده و این بازه ها در نتیجه اعمال

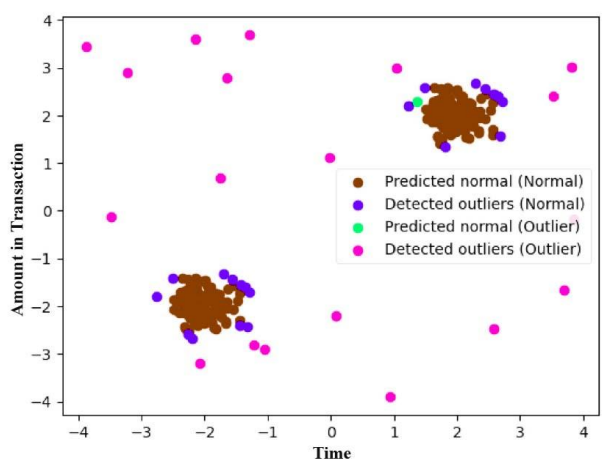
تکنیک Z-Score Normalization انتخاب شده است که باعث می شود تا مقادیر داده ها را در یک محدوده استاندارد قرار می دهد تا مدل های آماری بهتر عمل کنند. در نتیجه تمام داده هایی که در این بازه $[-4, 4]$ قرار می گیرند به حالت داده های نرمال در نظر گرفته شده و داده های خارج از این محدوده به عنوان نقاط پرت شناخته می شوند. مقیاس -4 تا 4 در این تحقیق، انتخاب شده است تا داده های نرمال و نقاط پرت به وضوح قابل مشاهده باشند و تحلیل آن ها راحت تر باشد. از طرفی، استفاده از بازه ی محدود باعث می شود که محاسبات کوواریانس و شناسایی نقاط پرت مؤثرتر انجام شود. لازم به ذکر است که، این بازه ی عددی بسته به روش تولید داده ها و هدف تحقیق ممکن است متفاوت باشد. شکل ۲، تصویر یک نمودار پراکندگی را نشان می دهد که داده ها را به دو گروه "داده های عادی" و "موارد خارج از قاعده" دسته بندی می کند. محور افقی برچسب "زمان" دارد، و محور عمودی نشان دهنده "مقدار تراکنش" است. این نمودار مشخص می کند که نقاط سبز نمایانگر "داده های عادی" هستند، و نقاط صورتی نشان دهنده "موارد خارج از قاعده" می باشند. نقاط سبز به طور عمده در دو گروه مجزا جمع شده اند: یکی در اطراف $(1, 2)$ و دیگری در اطراف $(-2, -2)$. در مقابل، نقاط صورتی پراکنده شده اند که نشان می دهد این موارد از الگوی معمولی خارج هستند. این نوع تصویر برای تحلیل تراکنش ها و شناسایی موارد غیرعادی بسیار مفید است.



شکل ۲- نمودار پراکندگی داده ها بر اساس دو ویژگی تعیین شده

○ پیاده سازی الگوریتم ها جنگل جداسازی iForest

شکل ۳ نتایج تشخیص ناهنجاری با استفاده از iForest را روی مجموعه داده های جمع آوری شده در این تحقیق نشان می دهد. این روش به جای ایجاد مرز برای جدا کردن ناهنجاری ها از مشاهدات عادی، آنها را جدا می کند.



شکل ۳- نتایج تشخیص ناهنجاری با اعمال الگوریتم iForest

در شکل ۳، نمودار دو گروه اصلی نقاط قهوه‌ای را نشان می‌دهد که حاکی از تراکنش‌های عادی است. در میان این نقاط، تعدادی نقاط بنفش دیده می‌شود که نشان‌دهنده ناهنجاری‌های شناسایی شده در میان تراکنش‌های عادی هستند. همچنین، نقاط صورتی پراکنده در نمودار نشان‌دهنده تراکنش‌هایی هستند که به عنوان ناهنجاری تشخیص داده شده‌اند. این نمودار به ارزیابی عملکرد الگوریتم تشخیص ناهنجاری کمک می‌کند. در زمینه‌هایی مانند شناسایی تراکنش‌های مشکوک یا تقلبی در سیستم‌های مالی بسیار مفید است.

○ پیاده‌سازی ماشین بردار پشتیبان یک کلاسه (One-Class SVM)

نتایج این پیاده‌سازی نشان می‌دهد که، SVM تک‌کلاسه با موفقیت اکثر نقاط داده نرمال را به درستی طبقه‌بندی کرده است و این نتیجه نشان‌دهنده توانایی مدل در تمایز بین داده‌های نرمال و ناهنجاری‌ها در یک مجموعه داده است و آن را به ابزاری مفید برای وظایف تشخیص ناهنجاری تبدیل می‌کند.

○ پیاده‌سازی عامل دورافتاده محلی (LOF)

با توجه به نتایج بدست آمده از این پیاده‌سازی، روش LOF، انحراف چگالی محلی یک نقطه داده معین را نسبت به همسایگانش ارزیابی می‌کند و هدف آن شناسایی مناطقی با چگالی مشابه و برجسته کردن نقاطی است که به عنوان ناهنجاری برجسته می‌شوند. روش LOF با تمرکز بر همسایگی محلی هر نقطه داده، به طور مؤثر داده‌های پرت را شناسایی می‌کند. این تکنیک به ویژه در مجموعه داده‌هایی که چگالی اطراف مشاهدات عادی و ناهنجاری‌ها به طور قابل توجهی متفاوت است، مفید است. همانطور که نشان داده شده است، مدل LOF با موفقیت داده‌های پرت مصنوعی حداقلی را به عنوان داده‌های پرت علامت‌گذاری کرده است (Cholevas, C. e. (2024)).

● پیاده‌سازی مرحله استانداردسازی نمرات ناهنجاری

پیاده‌سازی مرحله استانداردسازی نمرات ناهنجاری را با استفاده از زبان پایتون و کتابخانه‌های رایج مانند NumPy و Pandas انجام می‌دهیم. این مرحله معمولاً پس از اجرای الگوریتم‌های تشخیص ناهنجاری انجام می‌شود تا نمرات خروجی آن‌ها قابل مقایسه و ترکیب باشند.

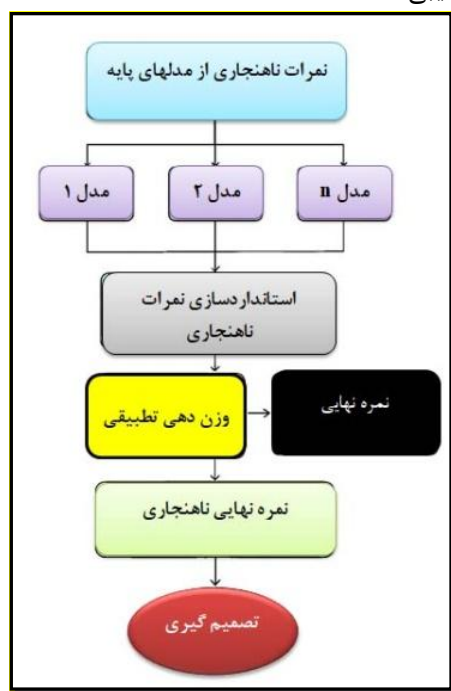
• پیاده سازی مرحله محاسبه وزن های تطبیقی

هدف از این مرحله، تخصیص وزن به هر الگوریتم بر اساس میزان توافق آن با سایر الگوریتم ها یا بر اساس توانایی اش در شناسایی ناهنجاری ها است. روش پیشنهادی برای این منظور، روش توافق مبتنی بر همبستگی است. در این روش، وزن هر الگوریتم بر اساس میانگین همبستگی آن با سایر الگوریتم ها محاسبه می شود. الگوریتم هایی که خروجی شان با سایر الگوریتم ها هم راستا تر باشد، وزن بیشتری می گیرند. این وزن ها نشان می دهند که هر الگوریتم چه سهمی در نمره نهایی دارد. اگر الگوریتمی خروجی متفاوت تری داشته باشد، وزنش کمتر خواهد بود.

• پیاده سازی مرحله تجميع نمرات ناهنجاری

نمودار تصویری فرآیند ترکیب نمرات ناهنجاری در مدل ترکیبی پیشنهادی در شکل ۴ مراحل زیر را به صورت گرافیکی نمایش می دهد.

- ✓ دریافت نمرات ناهنجاری از چند مدل پایه (مثل SVM, Isolation Forest, LOF)
- ✓ استاندارد سازی نمرات برای هم مقیاس سازی
- ✓ اعمال وزن های تطبیقی بر اساس عملکرد هر مدل
- ✓ محاسبه نمره نهایی با فرمول میانگین وزنی
- ✓ تصمیم گیری نهایی بر اساس نمره ترکیبی



شکل ۴- فرایند ترکیب نمرات ناهنجاری

- پیاده سازی مرحله تشخیص ناهنجاری: تشخیص ناهنجاری، یعنی تعیین اینکه کدام نمونه ها واقعاً ناهنجار هستند. این مرحله شامل تعیین آستانه (Threshold) و برچسب گذاری (Labeling) است. یکی از روش های رایج برای تعیین آستانه، استفاده از درصدی از داده ها است.

• ارزیابی کارایی روش پیشنهادی

جدول ۲ نتایج حاصل از ارزیابی کارایی روش پیشنهادی را نشان می دهد.

جدول ۲- نتایج ارزیابی کارایی روش پیشنهادی

مدل	دقت	صحت	فراخوانی	F1 Score
SVM تک کلاسه	٪۹۰٫۹	٪۵۰٫۱	٪۹۹٫۹	٪۶۶٫۷
SVM تک کلاسه با SGD	٪۹۱٫۴	٪۹۹٫۹	٪۵۰٫۱	٪۹۵٫۲
جنگل جداسازی	٪۹۰٫۵	٪۴۸٫۷	٪۹۵٫۱	٪۶۴٫۴
LOF	٪۸۲٫۷	٪۹۰٫۱	٪۹۹٫۱	٪۹۵٫۲
مدل ترکیبی	٪۹۹٫۶	٪۹۹٫۹	٪۹۹٫۹	٪۹۸٫۹

با توجه به جدول ۲ می توان نتیجه گیری کرد که، مدل های SVM تک کلاسه، دقت و صحت یکسانی را نشان می دهند و هر دو با موفقیت تمام داده های پرت را به خاطر می آورند که منجر به امتیاز F1 تقریباً ٪۶۶٫۷ می شود. نکته قابل توجه این است که SVM تک کلاسه با SGD به بالاترین دقت با ٪۹۱٫۴ دست می یابد که نشان می دهد مشاهدات عادی را به اشتباه به عنوان داده های پرت برچسب گذاری نمی کند. با این حال، کمترین میزان فراخوانی ٪۵۰٫۱ را دارد که نشان می دهد در شناسایی اکثر داده های پرت واقعی شکست می خورد، که این امر در امتیاز F1 پایین ٪۹۵٫۲ آن نیز منعکس شده است. مدل جنگل جداسازی، یک پروفایل متعادل با دقت مناسب (٪۹۰٫۵) و دومین میزان فراخوانی بالا (٪۹۵٫۱) را نشان می دهد که منجر به امتیاز F1 برابر با ٪۶۴٫۴ می شود. مدل «فاکتور داده های پرت محلی» در این مقایسه با کمترین دقت (٪۸۲٫۷) و امتیاز F1 برابر با ٪۹۵٫۲ (در کنار یک «بازخوانی» ماقبل آخر نسبت به «ماشین بردار پشتیبان تک کلاسه» با SGD، با مشکل مواجه است.

ماشین بردار پشتیبان تک کلاسه و «کوواریانس قوی» عملکرد متعادلی با امتیازهای برابر در بازخوانی و F1 (به ترتیب ٪۹۹٫۱ و ٪۶۶٫۷) نشان می دهند که نشان دهنده عملکرد قوی در تشخیص داده های پرت واقعی است. با این حال، دقت آنها متوسط است، که نشان می دهد برخی از نقاط عادی به اشتباه به عنوان ناهنجاری برچسب گذاری شده اند. «ماشین بردار پشتیبان تک کلاسه» با SGD دقت بالایی (٪۱۰۰٫۰) اما امتیاز بازخوانی و F1 بسیار پایینی (به ترتیب ٪۵۰ و ٪۹۵٫۲) نشان می دهد، که رویکرد محافظه کارانه آن را در برچسب گذاری داده های پرت برجسته می کند. این مدل بسیاری از داده های پرت واقعی را از دست می دهد، اما وقتی یک نقطه را به عنوان داده پرت برچسب گذاری می کند، بسیار دقیق است. جنگل جداسازی تعادل خوبی بین بازخوانی و دقت ایجاد می کند و به امتیاز F1 برابر با ٪۶۴٫۴ دست می یابد. این نتایج نشان دهنده توانایی قوی در شناسایی نقاط پرت ضمن حفظ نرخ معقولی از تشخیص های کاذب است. عامل پرت محلی کمترین عملکرد را در بین تمام معیارها نشان می دهد که نشان دهنده دشواری در تشخیص دقیق بین نقاط نرمال و نقاط پرت در این مجموعه داده است. همانطور که مشاهده می شود در روش ترکیبی همه معیارهای عملکردی دارای درصد بالاتری نسبت به تک تک مدل های استفاده شده به تنهایی می باشد. جدول ۳ تجزیه و تحلیل مقایسه ای از کارایی محاسباتی الگوریتم های تشخیص ناهنجاری بدون نظارت استفاده شده در این تحقیق را نشان می دهد.

جدول ۳- تجزیه و تحلیل مقایسه ای از کارایی محاسباتی الگوریتم های تشخیص ناهنجاری بدون نظارت استفاده شده در این پژوهش

مدل	زمان برازش مدل	زمان پیش بینی مدل	زمان رسم نتایج
SVM تک کلاسه	۰.۰۰۲	۰.۰۰۰۱	۱.۱۲۵
SVM تک کلاسه با SGD	۰.۰۰۲	۰.۰۰۰۱	۰.۴۵۶
جنگل جداسازی	۰.۲۰۴	۰.۰۰۴۰	۰.۴۰۵
LOF	۰.۰۰۸	۰.۳۰۱۲	۰.۰۵۰
روش ترکیبی	۰.۰۰۴	۰.۰۰۰۰۸	۰.۰۱

با توجه به جدول ۳ می توان استدلال کرد که، SVM تک کلاسه و SVM تک کلاسه با SGD سریع ترین زمان برازش مدل و پیش بینی داده های پرت را نشان می دهند، هر دو تنها ۰.۰۰۲ ثانیه برای برازش مدل و ۰.۰۰۰۱ ثانیه برای پیش بینی داده های پرت زمان می برند که نشان دهنده کارایی بالا در محیط های محاسباتی ساده تر است. نکته قابل توجه این است که هر دو الگوریتم زمان های بسیار متفاوتی برای ترسیم نتایج دارند، به طوری که SVM تک کلاسه در مقایسه با همتای SGD خود (۰.۴۵۶ ثانیه) به طور قابل توجهی طولانی تر (۱.۱۲۵ ثانیه) طول می کشد. جنگل جداسازی، در حالی که در برازش مدل (۰.۲۰۴ ثانیه) و پیش بینی داده های پرت (۰.۰۰۴۰ ثانیه) کندتر است، به زمان کمتری برای پیاده سازی نتایج (۰.۴۰۵ ثانیه) نیز نیاز دارد. ضریب داده های پرت محلی، زمان برازش مدل متوسطی (۰.۰۰۸ ثانیه) را نشان می دهد، اما زمان پیش بینی داده های پرت نسبتاً بالایی (۰.۳۰۱۲ ثانیه) دارد که نشان دهنده یک تعامل احتمالی بین سرعت برازش و پیچیدگی پیش بینی است. کوواریانس قوی، اگرچه کندترین زمان برازش مدل (۰.۰۶۰ ثانیه) را دارد، اما پیش بینی داده های پرت کارآمد (۰.۰۰۰۹ ثانیه) و سریع ترین ترسیم نتایج (۰.۰۱۴ ثانیه) را نشان می دهد. این تحلیل کارایی محاسباتی، عملکرد متفاوت تعامل بین مدل های مختلف تشخیص ناهنجاری را از نظر هزینه محاسباتی و کارایی برجسته می کند و بینش های ارزشمندی را برای انتخاب مدل های مناسب بر اساس الزامات کاربردی خاص ارائه می دهد. با توجه به جدول ۵، روش ترکیبی از نظر زمان برازش مدل نسبت به مدل های SVM تک کلاسه و مدل های SVM تک کلاسه با SGD بیشتر است ولی از نظر پیش بینی مدل و زمان رسم نتایج در مقایسه با تک تک مدل ها، بهبود یافته است و مدت زمان لازم برای پیش بینی مدل و رسم نتایج، در روش ترکیبی کاهش یافته است.

کارایی روش های مورد استفاده در این تحقیق را با روش های پیشنهادی توسط محققان دیگر [Kumari, S. e. (2024)., Bajpai, A. D. (2024)., Obeng, S. e. (2024).] از لحاظ معیارهای ارزیابی (شامل دقت، صحت و F1-Score) مورد مقایسه قرار می دهیم. جدول ۴ نتایج بدست آمده را نشان می دهد.

جدول ۴-مقایسه کارایی روش پیشنهادی با روش های دیگر

مدل	دقت	صحت	فراخوانی	F1 Score
SVM تک کلاسه	٪۹۰.۹	٪۵۰.۱	٪۹۹.۹	٪۶۶.۷
SVM تک کلاسه با SGD	٪۹۱.۴	٪۹۹.۹	٪۵۰.۱	٪۹۵.۲
جنگل جداسازی	٪۹۰.۵	٪۴۸.۷	٪۹۵.۱	٪۶۴.۴
LOF	٪۸۲.۷	٪۹۰.۱	٪۹۹.۱	٪۹۵.۲
مدل ترکیبی	٪۹۹.۶	٪۹۹.۹	٪۹۹.۹	٪۹۸.۹
روش مبتنی بر یادگیری عمیق [۲۳]	٪۸۹.۹	٪۹۱.۷	٪۹۹.۳	٪۹۴.۱
فاکتور پرت محلی (LOF) و رمزگذار خودکار [۲۲]	٪۸۸.۷	٪۸۵.۶	٪۸۴.۲	٪۸۶.۱
روش مبتنی بر فاصله [۲۵]	٪۷۱.۶	٪۶۹.۸	٪۶۸.۱	٪۶۹.۳

لذا با توجه به نتایج مندرج در جدول ۴، می توان گفت:

✓ روش مبتنی بر یادگیری عمیق ([Obeng, S. e. (2024).]) با تعادل عالی بین دقت و صحت به عنوان مدل خوبی محسوب می شود.

✓ مدل های متعادل: LOF کوواریانس قوی و SVM تک کلاسه با SGD گزینه های مناسبی برای داده های با توزیع نرمال

یا پیچیده هستند. در حالیکه روش ترکیبی پیشنهادی بهترین گزینه برای تمام داده ها به خصوص برای داده های با توزیع پیچیده می باشد.

✓ مدل های ضعیف شامل روش مبتنی بر فاصله ([Kumari, S. e. (2024).]) و جنگل جداسازی به دلیل صحت پایین، برای کاربردهای حساس توصیه نمی شوند.

نتیجه و جمع بندی

روش پیشنهادی در این تحقیق، برای تشخیص ناهنجاری در تراکنشهای انجام شده را بر روی انواع داده های تراکنشی (به عنوان مثال در بانکها، شبکه های ارتباطی، شبکه های اجتماعی و غیره) اعمال نموده و اقدام به شناسایی موارد ناهنجاری نمود و بدین وسیله کمک شایسته ای به افزایش امنیت داده ها و جلب رضایت و اعتماد مشتریان نمود. روش پیشنهادی با استفاده از داده های جمع آوری شده از پایگاه داده KDD ۹۹ که مربوط به تراکنشهای انجام شده توسط مشتریان یک بانک می باشد، پیاده سازی می شود. هر یک از پنج الگوریتم به طور انحصاری بر روی نقاط داده معمولی آموزش داده می شود. این مرحله بسیار مهم است زیرا به الگوریتم ها اجازه می دهد تا منطقه فضای ویژگی اشغال شده توسط کلاس اکثریت را بدون تأثیرپذیری از نقاط پرت یاد بگیرند. روش پیشنهادی با استفاده از مدل های آموزش دیده، ناهنجاری ها را با طبقه بندی هر نقطه داده در مجموعه داده توسعه یافته (از جمله نقاط پرت) به عنوان عادی یا پرت پیش بینی می کند. این مرحله توانایی هر مدل را برای تعمیم داده های آموزشی به داده های دیده نشده آزمایش می کند. ارزیابی بر اساس دقت، صحت، فراخوانی و امتیاز F1، قابلیت های متنوع این الگوریتم ها را در شناسایی داده های پرت، که هر کدام تحت تأثیر توزیع داده های اساسی، پیچیدگی الگوریتم و انتخاب پارامتر هستند، برجسته می کند.

مراجع

- Bajpai, A. D. (2024). "A novel methodology for anomaly detection in smart home networks via Fractional Stochastic Gradient Descent." . Computers and Electrical Engineering 119, 109604.
- Bakumenko, A. a. (2022). "Detecting anomalies in financial data using machine learning algorithms." . *Systems* 10.5., 130.
- Ball, R. S. (2023.). A machine learning-based framework for anomaly detection., *Diss. North-West University (South Africa)*, .
- Bolton, R. J. (2021). "Unsupervised profiling methods for fraud detection.",. *Credit scoring and credit control VII*, 235-255.
- Carcillo, F. e. (2021). "Combining unsupervised and supervised learning in credit card fraud detection." . Information sciences 557, 317-331.
- Cholevas, C. e. (2024). "Anomaly Detection in Blockchain Networks Using Unsupervised Learning: A Survey.",. *Algorithms* 17.5 , 201.
- Devavarapu, Y. e. (2024). "Credit Card Fraud Detection Using Outlier Analysis and Detection." . *4th International Conference on Intelligent Technologies (CONIT). IEEE*, .
- Gogoi, P. B. (2020). "Anomaly detection analysis of intrusion data using supervised & unsupervised approach." . *J. Convergence Inf. Technol.* 5.1., 95-110.
- Han, Dongqi, et al. (2021). "Deepaid: Interpreting and improving deep learning-based anomaly detection in security applications." *Proceedings of the 2021 ACM SIGSAC Conference on Computer and Communications Security*.
- Huang, D. e. (2018). "CoDetect: Financial fraud detection with anomaly feature detection." . *IEEE Access* 6., 19161-19174.
- Kim, Sujeong, Chanwoong Hwang, and Taejin Lee. (2020), "Anomaly based unknown intrusion detection in endpoint environments." *Electronics* 9.6: 1022.



- Kumar, Ankit, et al. (2021), "Distance based pattern driven mining for outlier detection in high dimensional big dataset." *ACM Transactions on Management Information System (TMIS)* 13.1 (2021): 1-17.
- Kumari, S. e. (2024). "A Comprehensive Investigation of Anomaly Detection Methods in Deep Learning and Machine Learning: 2019–2023." , *IET Information Security* 2024.1, 8821891.
- Minasyan, Arshak, and Nikita Zhivotovskiy. "Statistically optimal robust mean and covariance estimation for anisotropic Gaussians." *arXiv preprint arXiv: 2301.09024* (2023).
- Munir, M. e. (2018). "DeepAnT: A deep learning approach for unsupervised anomaly detection in time series.", *Ieee Access* 7,, 1991-.2005.
- Obeng, S. e. (2024). "Utilizing machine learning algorithms to prevent financial fraud and ensure transaction security.", *World Journal of Advanced Research and Reviews* 23.1,, 1972-1980.
- Schlör, D. (2022). *Detecting Anomalies in Transaction Data . (Doctoral dissertation, Universität Würzburg)*.
- Wang, Hongzhi, Mohamed Jaward Bah, and Mohamed Hammad. "Progress in outlier detection techniques: A survey." *IEEE Access* 7 (2019): 107964-108000.