

کشف تقلب در تراکنش‌های کارت‌های بانکی با استفاده از پردازش موازی ناهمجاري در بزرگ‌داده

محمد رضا تقوا^۱، طaha منصوری^۲، کامران فیضی^۳، بابک اخگر^۴

چکیده: با رشد روزافزون استفاده از کارت‌های الکترونیکی، به خصوص در صنعت بانکی، حجم تراکنش با این کارت‌ها نیز به سرعت افزایش پیدا کرده است. به علاوه، ذات مالی این کارت‌ها سبب ایجاد مظلومیت تقلب در این حوزه شده است. تحقیق حاضر با رویکرد پردازش موازی و راه حل نگاشت کاهش، از شبکه عصبی مدل کوهون برای کشف ناهمجاري در تراکنش کارت‌های بانکی استفاده کرده است. برای این منظور، در مرحله نخست راه حلی برای طبقه‌بندی تراکنش‌ها به تقلب‌آمیز و قانونی پیشنهاد شد که نسبت به روش‌های دیگر عملکرد بهتری از خود نشان داد. در مرحله بعد، روش پیشنهادی به دست آمده از تبدیل شبکه کوهون به فرم استفاده‌شده نگاشت کاهش، توانست قابلیت مناسبی را از نظر زمان اجرا به نمایش بگذارد؛ به طوری که انتظار می‌رود در تراکنش‌هایی با مفروضات بزرگ‌داده به خوبی پیاده‌سازی شود.

پژوهشگاه علوم انسانی و مطالعات فرهنگی

واژه‌های کلیدی: بزرگ‌داده، کارت‌های بانکی، کشف تقلب، مدل شبکه عصبی کوهون.

۱. دانشیار گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری دانشگاه علامه طباطبائی، تهران، ایران

۲. دانشجوی دکتری مدیریت فناوری اطلاعات، دانشکده مدیریت و حسابداری دانشگاه علامه طباطبائی، تهران، ایران

۳. استاد گروه مدیریت صنعتی دانشکده مدیریت و حسابداری دانشگاه علامه طباطبائی، تهران، ایران

۴. استاد گروه انفورماتیک، دانشگاه شفیلد هلム، شفیلد، انگلستان

تاریخ دریافت مقاله: ۱۳۹۵/۰۳/۰۹

تاریخ پذیرش نهایی مقاله: ۱۳۹۵/۰۶/۰۷

نویسنده مسئول مقاله: محمد رضا تقوا

E-mail: Taghva@gmail.com

مقدمه

رشد سریع و پیشرفت در حوزه تجارت الکترونیک، کاربرد کارت‌های بانکی را به عنوان ابزاری کارا برای انجام تعاملات الکترونیک افزایش داده است. در کنار همین رشد، تراکنش‌های تقلب‌آمیز نیز به صورت روزافزونی در حال افزایش است (میشرا، پاندا، و میشرا، ۲۰۱۳). تقلب کارت بانکی موضوعی حیاتی است که هزینه‌های شایان توجهی برای بانک‌ها و مؤسسه‌های صادرکننده کارت به دنبال دارد. سیستم‌های کشف تقلب با قابلیت تمیزداندن داده‌های تقلب‌آمیز از داده‌های قانونی و نمایان کردن رفتارهای متنقلبانه همراه با ایجاد قابلیت توسعه راهبردهای مناسب، در کاهش تأثیر آن برای تصمیم‌گیرندگان و کسبوکارها بسیار حیاتی هستند (گای، هو، ونگ، چن، و سان، ۲۰۱۱).

از آنجا که به راحتی نمی‌توان در خصوص انگیزه قانونی یا غیرقانونی بودن تراکنش‌ها حکم صادر کرد، بهترین و کم‌هزینه‌ترین ایده، رهگیری تقلب با استفاده از روش‌های ریاضی از میان داده‌های موجود است (فوآ، لی، اسمیت و گایلر، ۲۰۰۵). بنابراین، باید به کمک الگوریتم‌های داده‌کاوی بومی‌سازی شده، پایگاه‌های داده‌ای بزرگ را تحلیل کرد، با توجه به اهمیت تحلیل بزرگ‌داده برای صنایع مختلف و رشد و توسعه ابزارهای تجارت الکترونیک، به خصوص در حوزه کارت‌های بانکی، در ایران نیز حجم اینبویی از داده‌ها جمع‌آوری شده است و استخراج ارزش نهفته در این داده‌ها مانند نقاط دنیا بسیار اهمیت دارد. از سوی دیگر، همان‌طور که پیش‌تر اشاره شد، مسئله تقلب در این تراکنش‌ها بسیار جدی است؛ بنابراین هدف تحقیق حاضر یافتن مدل مناسب تحلیل داده‌های بزرگ از تراکنش کارت‌های بانکی، برای دستیابی به الگوهایی است که بتوان از طریق آنها تراکنش ورودی را به تراکنش قانونی یا تقلب‌آمیز طبقه‌بندی کرد.

بیان مسئله

در کشورهای دیگر، تحقیقات گسترده‌ای در خصوص استفاده از کارت‌های اعتباری صورت پذیرفته است، اما در ایران استفاده اعتباری از این کارت‌ها رایج نیست و اغلب تنها به صورت کارت پرداخت برخط استفاده می‌شود. علاوه‌بر اینکه در عمل نیز، سامانه‌های کشف تقلب فعالی در کشور وجود ندارند و حتی نسبت به سایر کشورها، تحقیقات در این زمینه بسیار اندک است (وثوق، تقوی‌فرد و البرزی، ۱۳۹۳). با در نظر گرفتن وضعیت حاکم بر بزرگ‌داده، به‌ویژه امکان‌نایذیری اجرای بسیاری از الگوریتم‌ها روی آن، تحقیقات صورت‌گرفته در کشور و سایر نقاط دنیا در این زمینه، بسیار محدود می‌شوند. یادآوری می‌شود که اصولاً داده‌ها زمانی بزرگ نامیده می‌شوند که سرعت تغییر، حجم و گوناگونی آنها بسیار بیشتر از توان سیستم فناوری اطلاعات موجود برای بازیابی، ذخیره، تحلیل و پردازش باشد (لوشن، ۲۰۱۳). کارت‌های بانکی،

یکی از اهداف مناسب برای متقلبان شناخته می‌شوند؛ زیرا چنانچه حمله‌کننده موفق شود، در زمان بسیار کوتاهی می‌تواند مقدار شایان توجهی پول برداشت کند، در حالیکه اغلب این برداشت در روزهای بعد شناسایی می‌شود (زریپور و شمس‌المعالی، ۲۰۱۵). همان‌گونه که گفته شد هدف مهم، شناسایی سریع تقلب و توقف آن در کوتاهترین فاصله زمانی ممکن پس از رخدادن است (نصیری و مینایی، ۱۳۹۱)؛ به این معنا که بتوان بی‌درنگ آزمایش داده‌های تراکنش را انجام داد و رفتارهای مبهم کاربر را قبل از تکمیل تراکنش کشف کرد (حلوایی و اکبری، ۲۰۱۴). این انتقال پردازش داده از بعد به قبیل از ذخیره‌سازی آن به شکل شایان توجهی زمان مقدور را برای ارزیابی تقاضاهای جدید از سیستم و به کارگیری تصمیم دقیقی برای کشف تقلب، کاهش می‌دهد (حلوایی و اکبری، ۲۰۱۴).

شایان ذکر است که روش‌های کشف تقلب آماری به دو زیرشاخه با سرپرستی و بدون سرپرستی تقسیم می‌شوند (زریپور و شمس‌المعالی، ۲۰۱۵). یکی از دغدغه‌های پژوهشگران انتخاب رویکرد مناسب‌تر از میان این دو است (دال-پوزولو، کائلن، لوبرین، واترشوت و بوتمپی، ۲۰۱۴). از یک سو الگوریتم‌های با سرپرستی به برچسب‌گذاری تراکنش‌های قبلی نیاز دارند و معمولاً تنها به الگوهای تقلیبی‌ای که در گذشته رخ داده است، محدود می‌شوند (دال-پوزولو و همکاران، ۲۰۱۴). از سوی دیگر، روش‌های غیرسرپرستی از طبقه تراکنش‌ها استفاده نمی‌کنند و می‌توانند رفتارهای تقلب‌آمیز جدید را نیز شناسایی کنند. به علاوه، درخصوص هر نوع روشی که از رویکردهای با سرپرستی استفاده می‌کند، انتقادهایی وارد است: ۱. هزینه محاسباتی زیادی دارند؛ ۲. زمان لازم برای برچسب‌زندن به مشاهدات جدید زیاد است؛ ۳. انحراف‌های ناشی از انتخاب نمونه می‌تواند سبب بروز خطا در برچسب‌های داده‌های آموخت شود (فوآ و همکاران، ۲۰۰۵).

با در نظر گرفتن این موارد، مسئله تحقیق حاضر، شناسایی سریع و درستی قابل قبول تقلب در تراکنش کارت‌های بانکی با استفاده از رویکرد غیرسرپرستی شبکه‌عصبی نقشه‌های خودسازمانده کوهونن در محیط بزرگ داده است. مطابق بررسی‌های صورت‌گرفته، مدل پیشنهادشده این پژوهش با استفاده از شبکه‌عصبی کوهونن و پردازش موازی در کشف ناهنجاری تراکنش کارت‌های پرداخت، نوعی نوآوری است و نمونه مشابهی در پژوهش‌های قبلی نداشته است. یکی از رویکردهای استفاده از روش باسرپرستی برای تشکیل الگوی دارنده کارت قانونی و متقلب، براساس یادگیری تراکنش‌های تاریخی و توسعه مجموعه‌ای از قواعد است. در رویکرد غیرسرپرستی، بیشتر کشف الگو دنبال می‌شود؛ به این معنا که اگر تراکنشی به الگوی

دارنده کارت قانونی مرتبط نباشد یا شبیه به الگوهای تقلب باشد، با عنوان مشکوک به تقلب طبقه‌بندی می‌شود (زالاوسکی و استریژاک، ۲۰۰۶).

پیشینهٔ پژوهش

پیشینهٔ نظری

به‌طور ساده، تقلب در کارت سوءاستفاده از آن بدون مجوز صاحب یا صادرکننده تعریف می‌شود (تریپاتی و راگا، ۲۰۱۳). چنانچه در محیط رقابتی تقلب شایع شود و سیستم پیش‌گیرنده و محدودکننده‌ای وجود نداشته باشد، می‌تواند به مسئله تهدیدکننده حیاتی برای کسبوکار و سازمان تبدیل شود (فوآ و همکاران، ۲۰۰۵). از سوی دیگر، با رشد سریع تعداد کارت‌های بانکی توزیع شده، طبیعی است که فعالیت‌های مجرمانه در این حوزه نیز افزایش یابد (زری‌پور، سیجا، علم و افسار، ۲۰۱۲). برخی از انواع شناخته شده تقلب در کارت‌های بانکی که معمولاً به صورت استفاده از شبکه ارتباطی یا با حضور فیزیکی کارت صورت می‌پذیرند، عبارت‌اند از: تقلب‌های فروشنده، تقلب‌های اینترنتی، کارت گمشده یا ربوده شده، در اختیار گرفتن حساب، استفاده‌نکردن از کارت، دریافت‌نکردن کارت، جست‌وجو در سطل زباله، کارت‌های جعلی، سرقت پستی، افشاء اطلاعات در محل کار یا منزل، شبکه‌های اجتماعی، تقلب ورشکستگی، تقلب دستگاه‌های خودپرداز و غصب‌کردن (وثوق و همکاران، ۱۳۹۳؛ نصیری و مینایی، ۱۳۹۱؛ زالاوسکی و استریژاک، ۲۰۰۶؛ سریواستاو، کوندو، سورال و ماجومدار، ۲۰۰۸). هدف از شناسایی تقلب، متوقف کردن آن در کوتاه‌ترین فاصله زمانی ممکن پس از رویداد است (وثوق و همکاران، ۱۳۹۳). فارغ از اینکه سیستم کشف تقلب مد نظر، به صورت دستی یا سیستمی است، اصولاً باید از ویژگی‌های زیر برخوردار باشد:

- باید کاملاً درست تقلب را تشخیص دهد، یعنی باید تراکنش اصلی با تراکنش تقلب‌آمیز اشتباه شود (درصد اعلان اشتباه آن پایین باشد) در غیر این صورت ممکن است کاربران نسبت به هشدارهای سیستم بی‌تفاوت شوند (اکسلسون، ۲۰۰۰؛)
- باید در کمترین زمان ممکن تقلب را تشخیص دهد (نصیری و مینایی، ۱۳۹۱).
- با وجود این، در زمینه کشف تقلب چالش‌های وجود دارد که به‌طور خلاصه عبارت‌اند از: در دسترس نبودن مجموعه داده‌های واقعی: یکی از محدودیت‌های مهم در این زمینه، نداشتن مجموعه داده‌های واقعی برای آزمون به‌دلایل امنیتی و کسبوکار است (زری‌پور و شمس‌المعالی، ۲۰۱۵؛ کیبی و چونهوا، ۲۰۱۱؛ گای و همکاران، ۲۰۱۱)؛

- مجموعه داده‌های نامتقارن: مجموعه داده‌های تراکنش کارت بهشت چولگی دارند؛ یعنی نسبت وجود تراکنش تقلب به تراکنش قانونی بسیار پایین است (کبی و چونهوا، ۲۰۱۱). معمولاً در وضعیت واقعی ۹۸ درصد از داده‌ها قانونی است و تنها ۲ درصد از آنها متقلبانه‌اند (زری‌پور و شمس‌المعالی، ۲۰۱۵؛ دال-پوزولو و همکاران، ۲۰۱۴؛ ویترو، هند، جوزاک، و وستن، ۲۰۰۸)؛
- اندازه مجموعه داده‌ها: هر روز میلیون‌ها تراکنش کارت بانکی انجام می‌شود (چان و همکاران، ۱۹۹۹) و تحلیل چنین مقدار بی‌شماری از اطلاعات به روش‌های بسیار مؤثر و مقیاس‌پذیر محاسباتی نیاز دارد (زری‌پور و شمس‌المعالی، ۲۰۱۵)؛
- رفتار پویای متقلب: متقلبان رفتار پویایی دارند، یعنی در طی زمان رفتار خود را در مقابل سیستم تغییر می‌دهند. بنابراین با سپری شدن زمان، تقلب‌ها نیز پیچیده‌تر می‌شوند (زری‌پور و شمس‌المعالی، ۲۰۱۵؛ کوریا بنسن، اوآوا، استوجانویچ، و اوترستن، ۲۰۱۶)؛ کمایش همه تراکنش‌های متقلبانه ظاهر قانونی دارند و چنانچه هر یک از آنها جداگانه بررسی شود، هیچ نشانه مشکوکی از آنها دیده نمی‌شود (وثوق و همکاران، ۱۳۹۳).

پیشینهٔ تجربی

در این بخش به پیشینهٔ عملی مطالعات صورت‌گرفته درخصوص کشف تقلب کارت‌های بانکی که معمولاً به عنوان کارت‌های اعتباری می‌شناسیم، پرداخته می‌شود. برای کشف تقلب در کارت‌های بانکی، از روش‌ها و الگوریتم‌های متعددی استفاده می‌شود که در زیر به بعضی از آنها اشاره شده است:

- الگوریتم‌های همجوشی اطلاعات مانند تئوری گواه دمپستر و شیفر و یادگیری بیزی (raig و پرتیا، ۲۰۱۱؛ برمودز، پرز، آیوسو، گومز و واژکوئز، ۲۰۰۸)؛
- مدل مخفی مارکوف (سریواستاوا و همکاران، ۲۰۰۸؛ بوساری و پاتیل، ۲۰۱۱)؛
- شبکه‌های عصبی (زری‌پور و همکاران، ۲۰۱۲؛raig و پرتیا، ۲۰۱۱؛ وثوق و همکاران، ۱۳۹۳؛ زاسلاوسکی و استریزاک، ۲۰۰۶؛ گرزالس و ولاسکوئز، ۲۰۱۳؛ اوژووسکی، ۲۰۱۴؛ پتیدار و شارما، ۲۰۱۱)؛
- الگوریتم ژنتیک (راماکالیانی و اومندوی، ۲۰۱۲؛ دومان و ازلیک، ۲۰۱۱)؛
- سیستم‌های ایمنی مصنوعی (حلوایی و اکبری، ۲۰۱۴).

سریواستاوا و همکارانش (۲۰۰۸) برای شناسایی تقلب در کارت‌های بانکی، از مدل مخفی مارکوف محدود با بهره‌مندی از رویکرد کشف ناهنجاری رفتاری استفاده کردند. اپیلارد و بوگیلا (۲۰۱۶) با استفاده از مدل مخفی مارکوف در داده‌های بهدست آمده از پردازش تصویر دوربین‌های شهری، بهدنبال کشف ناهنجاری بودند. وثوق و همکارانش (۱۳۹۳) برای تشخیص سریع تقلب در تراکنش‌های بانکی از مدل شبکه‌های عصبی مصنوعی چندلایه جلوسو بهره برداشتند. آنها از داده‌های واقعی استفاده کردند، اما به دلیل نداشتن برچسب، تراکنش‌های مشکوک را به کمک دانش خبرگان و ادبیات موضوع شبیه‌سازی کردند.

اولزووسکی (۲۰۱۴) به کمک مدل شبکه عصبی نقشه‌های خودسازمان‌ده، چارچوبی به منظور کشف تقلب ارائه داد. او با استفاده از بصری‌سازی رفتار کاربر و یک ماتریس یو¹، آستانه سنجش رفتار ناهنجار را تعیین کرد. گنزالس و ولاسکوئز (۲۰۱۳) در کار خود، برای مشخص کردن فرارهای مالیاتی از نوعی نقشه خودسازمانده برای ایجاد مدل کلی طبقه‌بندی استفاده کردند. هوانگ، سای و یو (۲۰۱۴) در پژوهش خود از یک کوهونن سلسه‌مراتبی رشدیابنده دوگانه استفاده کردند و آن را GHSOM نامیدند. این مدل برای کشف ناهنجاری در گزارش‌های مالی به کار رفته است. هلمن، ترسپ، و سیمولا (۱۹۹۹) بر اساس مدل شبکه عصبی نقشه خودسازمان دهند، نوعی سیستم کشف تقلب ارائه دادند که در آن مدل پس از آموزش با استفاده از مدل‌های احتمالی پروفایل کاربر، تقلب‌های احتمالی را براساس کشف ناهنجاری خوش‌بندی محور، شناسایی می‌کند. زاسلاوسکی و استریزاک (۲۰۰۶) با استفاده از مدل کوهونن، برای صاحب کارت پروفایل رفتار عادی ساختند. آنها ابتدا با استفاده از تراکنش‌های قبلی و شبکه کوهونن، ماتریس وزن‌ها را به عنوان پروفایل ذخیره کردند، سپس با اندازه‌گیری فاصله تراکنش ورودی با پروفایل بهدست آمده، میزان عادی یا ناهنجار بودن آن را بررسی کردند.

کوا و سریگانش (۲۰۰۸) با استفاده از شبکه‌های عصبی مدل کوهونن، سیستم خود را به سه لایه تقسیم کردند. مدل آنها ترکیبی و نیمه‌سپرستی است و در آن از یک شبکه عصبی کوهونن به همراه شبکه عصبی پرسپترون استفاده شده است. درخصوص کشف ناهنجاری در بزرگ‌داده نیز می‌توان به کار حلواپی و اکبری (۲۰۱۴) اشاره کرد که با استفاده از سیستم‌های ایمنی مصنوعی و مدل نگاشت کاهش در محیط پردازش ابر، نوعی مدل کشف تقلب با سپرستی ارائه دادند. هوانگ، ژو، یانگ و فنگ (۲۰۱۶) برای کشف ناهنجاری براساس رویکردهای چگالی محور، روش جست‌وجویی به نام جست‌وجویی همسایگی محلی ارائه دادند. به، وانگ، زین

و وانگ (۲۰۱۶) نیز بر کشف ارزش‌های ناهمجارت در محیط‌های بزرگ‌داده توزیع شده تمرکز کردند. روش استفاده‌شده آنها کشف ناهمجارت چگالی محور است. با بررسی پیشینه عملی مشاهده می‌شود، هیچ‌یک از مدل‌های بدون سرپرستی شبکه عصبی کوهون، به صورت ترکیب با نگاشت کاهش برای غلبه بر الزامات بزرگ‌داده استفاده نکرده‌اند.

مدل مفهومی

همان‌گونه که پیش از این بیان شد، مسئله تحقیق شناسایی سریع و با درستی قابل قبول تقلب در تراکنش کارت‌های بانکی است.

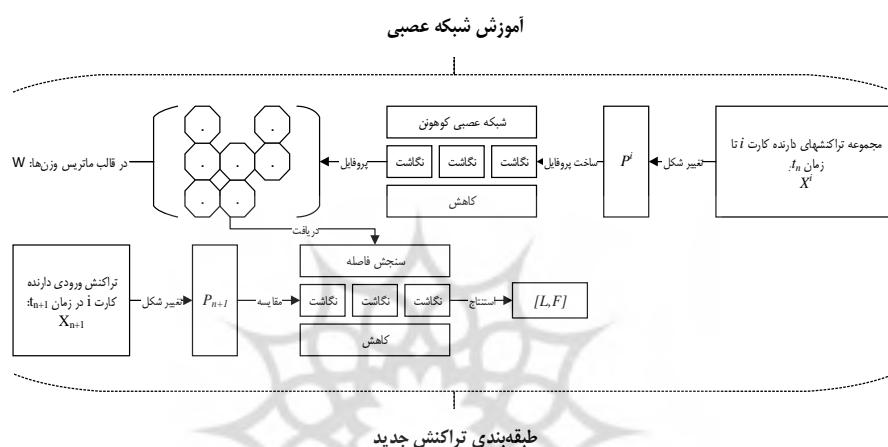
در نظر بگیرید که در یکی از پایگاه‌های داده، مجموعه‌ای مانند $\{c_1, c_2, \dots, c_{k_n}\}$ به عنوان مجموعه کارت‌های ذخیره‌شده در سیستم پرداخت و زیرمجموعه $\{c_s^i, c_i = \{1, \dots, c_i^i\}, \dots, c_s^l\}$ ، کارتی متشکل از S ویژگی است. در ضمن، مجموعه بزرگ $\{|X|^1, |X|^2, \dots, |X|^{k_s}\} = X$ ، کل تراکنش‌های موجود در سیستم و $\{\vec{X}_1^i, \dots, \vec{X}_{n+1}^i\} = |X|^i$ ، رکوردهای مربوط به کارت شماره i تا زمان t_n است. هر یک از این رکوردها، بردارهایی مانند $\{x_j^1, \dots, x_j^m\} = \vec{x}_j$ هستند که از m ویژگی عددی یا اسمی تشکیل شده‌اند. $\vec{X}_{n+k}^i, \dots, \vec{X}_{n+1}^i$ نیز تراکنش‌های پس از زمان t_n هستند. حال برای کارتی مانند θ ، مسئله یافتن قانونی یا تقلب‌آمیز بودن تراکنش \vec{X}_{n+1}^i در کمترین زمان ممکن است. مجموعه X از تراکنش‌های سیستم پرداخت به دو زیرمجموعه جمع‌ناپذیر تقسیم قانونی $\subseteq X^1$ و تقلب‌آمیز $\subseteq X^f$ به طوری که $X^f \cap X^1 = \emptyset$ تقسیم می‌شود. اگر فرض بر این قرار گیرد که تصویر عددی (نقاط موجود در برخی از فضاهای چندبعدی) از تراکنش‌های قانونی و تقلب‌آمیز به زیرفضاهای متفاوتی تعلق دارند؛ ممکن است درباره نگاشت تراکنش جدیدی مانند \vec{X}_{n+1}^i به هر یک از زیرفضاهای، تصمیم‌گیری شود. فضای تصمیم برای طبقه‌بندی تراکنش جدید از رابطه (1) به دست می‌آید.

$$\Theta = \{\theta_f, \theta_l\} \quad (1)$$

در این رابطه، θ_f و θ_l به ترتیب تقلب‌آمیز یا قانونی بودن تراکنش هستند. بنابراین، عضویت تراکنش به هر یک از زیرفضاهای یادشده براساس میزان مشابهت \vec{X}_{n+1}^i ، به زیرمجموعه X^l و از طریق آموزش یک پروفایل از رفتار هنجار دارنده کارت، سنجیده می‌شود. بنابراین، با توجه به هدف تحقیق، مدل ریاضی به صورت رابطه 2 است که در آن E خطای طبقه‌بندی، t_d زمان یافتن پاسخ و $(X_{n+1}^i)g$ تابع طبقه‌بندی است.

$$\begin{aligned} \min z &= \langle t_d, E \rangle \\ \text{st: } g(X_{n+1}) &\in \Theta \end{aligned} \quad \text{رابطه (۲)}$$

شکل ۱ مدل مفهومی پژوهش را با در نظر گرفتن اهداف آن، یعنی دقت و سرعت در طبقه‌بندی نشان می‌دهد.



شکل ۱. مدل مفهومی پیشنهادی کشف تقلب در تحقیق حاضر

روش‌شناسی پژوهش

در این بخش به تعیین ویژگی‌های لازم برای تشکیل پروفایل رفتار دارنده کارت، گردآوری و پیش‌پردازش داده‌ها و مدل‌سازی حل تابع هدف مسئله تحقیق پرداخته خواهد شد.

ویژگی‌های رفتاری

کشف تقلب با توجه به تحلیل عادت استفاده از کارت، راه حل امیدوارکننده‌ای است (سریواستاوا و همکاران، ۲۰۰۸)؛ به این معنا که افراد معمولاً تمایل دارند بعضی از ویژگی‌های خاص رفتاری را به نمایش بگذارند. بنابراین، هر دارنده کارت می‌تواند به وسیله مجموعه الگوهایی که انحراف از آنها رفتار مشکوک بالقوه‌ای است، به نمایش درآیند (زاسلامسکی و استریثاک، ۲۰۰۶). هنگام ساخت مدل کشف تقلب، مجموعه اولیه ویژگی‌ها شامل اطلاعات مربوط به تراکشن تکی است (کوریا بنسن و همکاران، ۲۰۱۶). مدل‌های بسیاری از این ویژگی‌های خام استفاده کرده‌اند (مینگیشی و نیمی، ۲۰۱۱؛ سریواستاوا و همکاران، ۲۰۰۸)، اما استفاده از این داده‌های خام به

بیرون کشیدن رفتار مالک منجر نخواهد شد (کوریا بنسن و همکاران، ۲۰۱۶). ویترو و همکارانش (۲۰۰۸) برای به تصویر کشیدن عادت رفتاری صاحب کارت، راهبرد استفاده از ویژگی‌های تجمعی شده را ارائه دادند. به عقیده کوریا بنسن و همکارانش (۲۰۱۶)، راه بهتر، تکمیل رویکرد ویترو و استفاده از ویژگی‌های تجمیعی تراکنشی است. این ویژگی‌های تجمیعی شامل گروه‌بندی تراکنش‌های انجام‌شده در آخرین دوره زمانی به تفکیک اشاره شده در بالا می‌شوند. این رویکرد در پژوهش‌های متعددی استفاده شده است (زالاوسکی و استریپاک، ۲۰۰۶؛ جها، گویین، و وستلن، ۲۰۱۲؛ دال-پوزولو و همکاران، ۲۰۱۴؛ کوریا بنسن و همکاران، ۲۰۱۶). بر همین اساس، در این تحقیق پس از بررسی ویژگی‌های یادشده توسط خبرگان، ویژگی‌های ترکیبی مانند، جمع ارزش پولی تراکنش، تعداد تراکنش در ۱ ساعت گذشته و... و ارزش پولی تراکنش و میانگین ساعت‌های استفاده در قالب هشت ویژگی برای استخراج الگوی رفتاری دارنده کارت در نظر گرفته شد.

گردآوری و پیش‌پردازش داده‌ها

برای این تحقیق از داده‌های واقعی یکی از بانک‌های فعال کشور که از کارت‌های الکترونیکی استفاده می‌کند، با در نظر گرفتن شرایط محرمانگی، استفاده شد. تراکنش‌های ۱۵۷۹۷ کارت در یک بازه چهارماهه به صورت تصادفی انتخاب شد. در گام نخست تعداد تراکنش‌ها ۷۲۲۹۸ بود. با توجه به اثربخش نبودن مدل با تعداد تراکنش اندک برای دارنده کارت (زالاوسکی و استریپاک، ۲۰۰۶)، کارت‌هایی که در این بازه کمتر از ۵۰ تراکنش داشتند، حذف شدند. از سوی دیگر، با بررسی استناد بانک یادشده، تعدادی تراکنش تقلب‌آمیز کشف شد. آنها تراکنش‌هایی بودند که مشتریان به عنوان غیرقابل قبول و فهرست سیاه معروفی کردند بودند. با توجه به تعداد اندک آنها و پس از بررسی الگوهای ایشان و به کارگیری نظر خبرگان، به منظور اعتبارسنجی مدل برای رسیدن به مقدار ۲ درصد تراکنش تقلب‌آمیز، نویزی با توزیع نزدیک به نظر خبرگان و الگوی تراکنش‌های تقلب‌آمیز استخراج شد و به آن تعدادی تراکنش قانونی داده شد و آنها را برچسب‌دار کرد. در گام بعدی تراکنش‌های قانونی‌ای که ارزش‌های پرت داشتند از مجموعه داده حذف شدند. پس از حذف این تراکنش‌ها، درنهایت تعداد کارت‌ها به ۸۹۰۰ و تراکنش‌ها به ۵۸۰۵۰۸ رسید. ۹۰ درصد از تراکنش‌ها برای ساخت پروفایل و ۱۰ درصد برای آزمون مدل استفاده شدند. در مجموع، در داده‌های آزمون ۱۱۲۲ تراکنش تقلب‌آمیز وجود داشت. از آنجا که در این تحقیق از ویژگی‌های خام تراکنش استفاده نمی‌شود و به جز مقدار پولی تراکنش، باقی ویژگی‌ها به صورت ترکیبی در یک بازه زمانی هستند، از رابطه^۳ به منظور تبدیل کننده تراکنش‌های خام به شکل ترکیبی تراکنش استفاده می‌شود.

$$Tr(X, Du) = P: R^s \rightarrow R^8 \quad \text{رابطه (۳)}$$

در رابطه ۳، X مجموعه تراکنش‌های یک کارت، و Du بازه زمانی مد نظر برای تجمعیع و P صورت تغییریافته تراکنش‌هاست. به علاوه، محاسبه ویژگی میانگین ساعت‌های تراکنش برای یک دوره، با توجه به کارایی نبودن میانگین با پیشنهاد کوریا بنسن و همکارانش از توزیع ون میزز^۱ (بیشاپ، ۲۰۰۶) استفاده شد (کوریا بنسن و همکاران، ۲۰۱۶). درنهایت برای نرمال‌سازی نیز از مبدل دوقطبی استفاده شده است.

ساخت مدل

در این بخش برای دستیابی به هدف تحقیق به ساخت مدل پرداخته می‌شود. همان‌گونه که بیان شد، رویکرد تحقیق استفاده از مدل‌های بدون سرپرستی است، بنابراین از شبکه عصبی کوهونن برای ایجاد پروفایل دارنده کارت و سنجش میزان انحراف تراکنش جدید از پروفایل ایجادشده و از رویکرد نگاشت کاهش برای موازی‌سازی اجرای این مدل استفاده شده است.

نقشه‌های خودسازمانده، شبکه‌های عصبی‌ای هستند که می‌توانند فضای ورودی چندبعدی را به فضای خروجی دو بعدی نگاشت کنند (کوهونن، ۱۹۹۰). مدل کوهونن دو فاز دارد؛ در فاز آموزش، نقشه‌ها ساخته می‌شوند و در فاز پیش‌بینی، یک بردار ورودی به نزدیکترین نقشه نگاشت می‌شود (کوهونن، ۱۹۹۰). در این شبکه با واردشدن بردار، تنها بخشی از شبکه به روز می‌شود (رجاس، ۱۹۹۶). فرایند خودسازماندهی براساس آموزش رقابتی است و شامل تنظیم ماتریس وزن‌ها یا W^1 تشکیل شده از k (تعداد نرون‌ها) بردار ستونی m (تعداد ویژگی‌ها) در یک فرایند تکراری، با توجه به بردار ورودی می‌شود (کوهونن، ۱۹۹۰). در این تحقیق، ماتریس وزن‌ها پس از آموزش شبکه با استفاده از قاعدة یادگیری کوهونن (کوهونن ۱۹۹۰) ایجاد می‌شود.

$$\vec{w}_l^{t+1} = \vec{w}_l^{t+1} + h(t) \cdot \eta(t) (\vec{x}_l^t - \vec{w}_l^t) \quad \text{رابطه (۴)}$$

که در آن، t زمان یا تکرار، \vec{w}_l نماد l امین ($l = 1, \dots, k$) بردار m عضوی از ماتریس وزن‌ها، h تابع همسایگی (تابعی از زمان و R یا شاعع همسایگی)، η ضریب یادگیری و \vec{x}_l بردار ورودی m عضوی مرتبط با نرون l است. جدول ۱ به صورت خلاصه الگوریتم یادگیری کوهونن را نشان می‌دهد.

-
1. Von Mises distribution
 2. Self organizing maps (SOM)

جدول ۱. الگوریتم یادگیری کوهونن

آغاز الگوریتم:

۱. وزن دهی تصادفی ماتریس وزن‌ها (W)، مقداردهی ضریب یادگیری اولیه η . شدت همسایگی اولیه σ ، شاعع همسایگی R وتابع همسایگی h .
 ۲. برای همه بردارهای ورودی (\vec{x}_i به ازای $i = 1 \dots n$) تعداد مشاهدات است:
 - سنجش فاصله بردار انتخاب شده با همه نمونه‌ها و یافتن بهترین نمونه برآزنده^۱
- $BNF = Argmin(d(\vec{x}_i, \vec{w}_j); j = 1 \dots k)$ رابطه (۵)
- در رابطه ۵ $d(\dots)$ معیار فاصله است.
- با در نظر گرفتن شاعع همسایگی، به روزرسانی وزن‌های بهترین نمونه برآزنده و همسایه‌هایش با استفاده از رابطه ۱.
 - ۳. به روزرسانی، ضریب یادگیری و شدت همسایگی
 - ۴. سنجش شرط پایان حلقه (ممکن تعداد تکرار) در غیر این صورت رفتنه به گام ۲

پایان الگوریتم

منبع: کتو و دشپاند (۲۰۱۵)

در فاز پیش‌بینی، بردار ورودی جدید (\vec{x}_{n+1}) با همه نمونه‌ها سنجیده می‌شود و نزدیک‌ترین نمونه، به عنوان برنده این بردار ورودی، شناخته خواهد شد.

$$Cluster = Argmin(d(\vec{x}_{n+1}, \vec{w}_j); j = 1 \dots k) \quad \text{رابطه (۶)}$$

قبل از معرفی روش پیشنهادی، مختصراً درباره نگاشت کاهش که اساسی برای پردازش توزیعی بزرگ‌داده‌های است، توضیح داده می‌شود. نگاشت کاهش نوعی مدل توسعهٔ سیستم برای محاسبات موازی و توزیع شده است که حجم‌های عظیم داده‌ها را مدیریت می‌کند. این مدل دو عملگر دارد که به صورت مجموعه یا زوج‌های کلید/ ارزش، نتایج را بازمی‌گردانند (دین و قماوات، ۲۰۰۴). عملگر نگاشت اجرای بخشی از تحلیل را برعهده دارد و محاسبه یا تحلیل‌ها را در مجموعه‌های از زوج‌های کلید/ ارزش میانی وارد می‌کند (دین و قماوات، ۲۰۰۴). کاهش این عملگر، مجموعه زوج‌های تولیدشده توسط نگاشتها را به عنوان ورودی دریافت‌کرده و برای دستیابی به نتیجهٔ نهایی تحلیل، پس از پردازش آنها، این مجموعه‌ها را با کلید نهایی مرتبط می‌کند. با استفاده از این عملگرهای، هر برنامه نگاشت کاهش می‌تواند مجموعه‌ای متوالی از وظایف موازی را روی حجم عظیمی از داده‌ها انجام دهد (لسکوک، راجارمان، و اولم، ۲۰۱۴). ترکیب دو ویژگی استقلال داده‌ها و استقلال محاسباتی، این دست‌آورد را به ارمنان می‌آورد که بتوان وظایف را به صورت توزیع شده و موازی پیاده‌سازی کرد. این قابلیت به توسعه‌دهنده اجازه

1. Best fitted neuron (BNF)

می‌دهد که از مقیاس‌پذیری نتایج پردازش موازی در مقیاس عظیم، برای افزایش سرعت پردازش و عملکرد بهره‌مند شود (لסקوک و همکاران، ۲۰۱۴).

برای ایجاد پروفایل، دارنده کارت i با استفاده از مدل کوهون، X^i نشان‌دهنده رکوردهای مربوط به کارت i تا زمان t_n است که از طریق رابطه ۳ و نرمال‌سازی به مجموعه تجمعی P^i تبدیل می‌شود. برای تولید ماتریس k برداری، W^i که وزن‌های آموزش‌دیده نرون‌های به دست‌آمده از آموزش شبکه براساس ورودی‌های ماتریس i است؛ از الگوریتم پیشنهادی مندرج در جدول ۲، استفاده می‌شود.

جدول ۲. الگوریتم پیشنهادی برای آموزش شبکه عصبی کوهون براساس نکاشت کاهش

آغاز الگوریتم:

۱. وزن‌دهی تصادفی ماتریس وزن‌ها (W)، مقداردهی ضریب یادگیری اولیه σ ، شعاع همسایگی R و تابع همسایگی h .

۲. برای هر بردار ورودی p^i_j (۰ شماره کارت، و $j=1 \dots n$ تعداد بردارهای ورودی)، فرایند نگاشت به تعداد M تا رسیدن به آخرین نرون به صورت موازی اجرا می‌شود ($M \leq k$):

- نگاشت به صورت زیر تعریف می‌شود:

$$\text{map}(p^i_j, w_h^i) = \langle h, d(p^i_j, w_h^i) \rangle \quad (\text{رابطه ۷})$$

• رابطه، فاصله زمین ورودی را با h این نرون می‌سنجد و مقدار فاصله را در قالب زوج کلید و ارزش <شماره نرون، میزان فاصله> باز می‌گرداند.

• در گام کاهش، پس از به پایان رسیدن همه نگاشتها در قالب تک‌فرایند نخست، بهترین نرون برازنده با دادن فهرستی از کلید، ارزش‌های مجموعه نگاشت به صورت رابطه محاسبه می‌شود:

$$BNF(list \langle h, d(p^i_j, w_h^i) \rangle) = \text{Key} \min_{h=1 \dots k} (v_h) \quad (\text{رابطه ۸})$$

• سپس در همین گام کاهش با در نظر گرفتن شعاع همسایگی، به روزسانی وزن‌های بهترین نرون برازنده و همسایه‌هایش با استفاده از رابطه ۴ صورت می‌پذیرد.

۳. به روزسانی، ضریب یادگیری و شدت همسایگی

۴. سنجش شرط پایان حلقه (ممولاً تعداد تکرار) در غیر این صورت رفتن به گام ۲

پایان الگوریتم

شایان ذکر است، تابع فاصله همان تابع فاصله اقلیدسی اشاره شده در رابطه ۹ است.

$$d(\vec{P}, \vec{W}) = \sqrt{\sum_{i=1}^m (p_i - w_i)^2} \quad (\text{رابطه ۹})$$

پس از طی فرایند یادشده برای همه کارت‌ها و براساس مجموعه آموزش که تشکیل شده از صورت تغییریافته تجمعی و نرمال‌شده مجموعه آموزش است؛ نوبت به سازوکاری برای سنجش احتمال ناهنجاری و متعاقب آن، تقلب تراکنش ورودی براساس ماتریس W^i به دست‌آمده است.

در ادامه، نخست با توجه به اینکه فاصله معياری پیوسته و طبقه‌بندی معمولاً دوقطبی است، راه حل‌های موجود در خصوص تراکنش ناهنجار بررسی می‌شود، دوم روش پیشنهادی این پژوهش برای تشخیص تراکنش ناهنجار ارائه شده و الگوریتمی برای سنجش موازی فاصله تراکنش ورودی با پروفایل آموزش دیده، معرفی خواهد شد.

یکی از رویکردهایی که برای محاسبه مقدار مشابهت میان \vec{X}_{n+1} با W^i به کار می‌رود، یافتن نزدیک‌ترین نرون و مقایسه فاصله تراکنش ورودی با آن نرون با آستانه یکسان است. محققان معتقدند هرچه فاصله بیشتر باشد، احتمال تقلب نیز بیشتر خواهد بود (زاسلاموسکی و استریزاک، ۲۰۰۶). در رویکرد دوم، نرونی که بیشترین عدد را در ماتریس Y^i به خود تخصیص می‌دهد، به عنوان مرز آستانه در نظر گرفته می‌شود. ماتریس Y^i ، شکلی از نمایش در توری شبکه کوهونن است که همه نرون‌ها وارد آن می‌شوند و پس از سنجیدن تفاوت آنها با همسایه‌هایشان، نرون‌ها از کمترین بی‌تشابهی با همسایه‌ها تا بیشترین مرتب می‌شوند. بنابراین، در این ماتریس نوعی توالی از ارزش‌های بالا با پراکندگی زیاد وجود دارد. با توجه به این ماتریس، آستانه به صورت رابطه ۱۰ محاسبه می‌شود. در رابطه ۱۰، τ ارزش آستانه، C مرکز کلی توری شبکه، v_{max} نرونی بیشترین ارزش در ماتریس Y^i را دارد (نرونی که درصد مشابه‌بودن آن با همسایه‌هایش بیشتر است) و $d(C, v_{max})$ معیار فاصله است (اولزووسکی، ۲۰۱۴).

$$\tau = d(C, v_{max}) \quad (10)$$

در این رویکرد برای یافتن تراکنش ناهنجار،تابع منطقی رابطه ۱۱، برای همه ورودی‌ها محاسبه می‌شود. در این رابطه، p_{n+1} تراکنش ورودی تغییریافته جدید، v_{n+1} نرون مربوط به تراکنش ورودی ذکرشده و φ تابع منطقی مقایسه است.

$$\varphi(p_{n+1}) = \begin{cases} \text{true}, & d(v_{n+1}, C) > \tau \\ \text{false}, & d(v_{n+1}, C) \leq \tau \end{cases} \quad (11)$$

در رویکرد پیشنهادی، مقدار به دست آمده از رابطه ۱۰ در نظر گرفته می‌شود، سپس به کمک رابطه ۱۲، شاخص دیگری با عنوان میانگین فاصله نامتشابه‌ترین نرون، محاسبه می‌گردد.

$$\rho = \text{mean}(d_{j=1, \dots, \pm R}(v_{max}, v_j)) \quad (12)$$

حال فاصله تراکنش ورودی با نزدیکترین نرون محاسبه می‌شود. رابطه ۱۳ تابع منطقی برای بررسی قانونی یا تقلب‌آمیز بودن تراکنش را نشان می‌دهد.

$$\phi(p_{n+1}) = \begin{cases} \text{true}, d(v_{n+1}, p_{n+1}) > \tau + \rho \\ \text{false}, d(v_{n+1}, p_{n+1}) \leq \tau + \rho \end{cases} \quad (13)$$

برای سنجش طبقه‌بندی موازی تراکنش ورودی براساس پروفایل، پس از تغییر شکل تراکنش، از الگوریتم پیشنهادی جدول ۳ استفاده می‌شود.

جدول ۳. الگوریتم پیشنهادی برای سنجش فاصله تراکنش ورودی با پروفایل دارنده کارت

برای بردار ورودی P_{n+1}^i (شماره کارت)، فرایند نگاشت به تعداد M تا رسیدن به آخرین نرون به صورت موازی اجرا می‌شود ($k \leq M$ ، k تعداد نرون‌هاست):
نگاشت به صورت زیر تعریف می‌شود:

$$\text{map}(P_{n+1}^i, w_h^i) = \langle h, d(P_{n+1}^i, w_h^i) \rangle \quad (14)$$

رابطه ۱۴، فاصله زامین ورودی را با h این نرون می‌سنجد و مقدار فاصله را در قالب زوج کلید و ارزش (شماره نرون، میزان فاصله) بازمی‌گرداند.

در گام کاهش، پس از به پایان رسیدن همه نگاشتها در قالب تک‌فرایند؛ نخست فاصله تراکنش ورودی با نزدیکترین نرون را یافته و همزمان فاصله نرون یادشده با مرکز توری شبکه، سنجیده می‌شود:

$$\text{Reduce}(\text{list} \langle h, d(P_{n+1}^i, w_h^i) \rangle) = \langle \min_{h=1 \dots k} (v_h), d(v_{n+1}, C) \rangle \quad (15)$$

یافته‌های تحقیق

برای سنجش عملکرد الگوریتم این تحقیق در طبقه‌بندی، معیارهای طبقه‌بندی استفاده می‌شوند.
جدول ۴ ماتریس درهم‌ریختگی طبقه‌بندی را به تصویر می‌کشد. بر همین اساس معیارهای جدول ۵ محاسبه می‌شوند.

جدول ۴. ماتریس درهم‌ریختگی الگوریتم‌های طبقه‌بندی

کل جامعه	شرایط درست	شرایط نادرست
پیش‌بینی مثبت	اعلان درست ^۱	اعلان نادرست ^۲
پیش‌بینی منفی	عدم اعلان نادرست ^۳	عدم اعلان درست ^۴

منبع: سوئیت (۱۹۹۶)

1. True Positive (TP)
2. False Positive (FP)
3. False Negative (FN)
4. True Negative (TN)

جدول ۵. شاخص‌های مختلف سنجش عملکرد طبقه‌بندی

نام شاخص	فرمول
صحت یا درستی	$Acc = \frac{\sum TP + \sum TN}{Total Population}$
اعلان درست یا حساسیت یا فراخوان ^۱	$TPR = \frac{\sum TP}{\sum P}$
عدم اعلان نادرست یا از دست دادن ^۲	$FNR = \frac{\sum FN}{\sum P}$
اعلان نادرست یا مشاجره ^۳	$FPR = \frac{\sum FP}{\sum N}$
عدم اعلان درست یا ویژگی ^۴	$TNR = \frac{\sum TN}{\sum N}$
آماره F_1	$F_1 = \frac{2TP}{2TP + FP + FN}$
g-mean _۱	$\sqrt{TPR \times TNR}$

(۲۰۱۱) منبع: پاورز

ابتدا براساس الگوریتم جدول ۱، شبکه کوهون را آموزش‌داده و داده‌های آزمون وارد آن می‌شوند. برای ارزش برش، از عدد ۱ تا ۱۰ درصد استفاده شد. جدول ۶ نتایج به دست آمده را در هر سطح برش به تصویر می‌کشد.

جدول ۶. نتیجه آزمون براساس مقادیر برش (به درصد) و فاصله با نزدیک‌ترین نرون

شاخص	۱۰	۹	۸	۷	۶	۵	۴	۳	۲	۱
حساسیت	۸۰	۷۷	۷۴	۷۴	۷۳	۶۰	۴۶	۴۱	۳۵	۲۵
از دست دادن	۷۷	۷۳	۶۹	۶۵	۶۱	۵۶	۵۳	۴۰	۳۶	۲۹
درستی	۲۶	۲۸	۳۳	۳۹	۴۰	۴۷	۵۲	۶۰	۶۴	۷۰
F_1	۴	۴	۴	۴	۵	۴	۳	۴	۴	۳
g-mean _۱	۴۳	۴۵	۴۸	۵۱	۵۴	۵۱	۴۶	۵۰	۴۷	۴۳

1. Recall

2. Miss

3. Fall out

4. Specificity

همان‌گونه که جدول ۶ نشان می‌دهد، استفاده از رویکرد مقدار برش ثابت برای همه پروفایل‌ها و سنجش فاصله با نزدیک‌ترین نرون، طبقه‌بندی مناسبی انجام نمی‌دهد. با در نظر گرفتن اطلاعات این جدول، بیشترین حساسیت و از دستدادن، مربوط به مقدار برش 10 درصد است. از سوی دیگر، بیشترین درستی برای برش 1 درصد و بیشترین مقدار $g\text{-mean}_r$ مختص به برش 6 درصد است. در خصوص آماره F_1 اساساً این روش در جایگاه مناسبی قرار ندارد. در گام دوم و سوم از روش استفاده شده اولزووسکی ($20/14$) و رویکرد پیشنهادی برای طبقه‌بندی استفاده شد. جدول ۷ ماتریس درهم‌ریختگی براساس روش زاسلاوسکی و جدول ۸ این ماتریس را برای روش پیشنهادی نشان می‌دهد.

جدول ۹ نیز نتایج حاصل را برای هر دو روش به تصویر می‌کشد. نکته شابان توجه اینکه هر دو روش عملکرد چشمگیری را از خود نشان دادند. البته، روش پیشنهادی عملکرد مناسب‌تری دارد، به طوری که توانسته است به صحت 94 درصد دست یابد. مهم‌ترین نکته موقفيت این دو روش را می‌توان در استفاده تطبیقی ارزش برش برای هر دارنده کارت به صورت جداگانه دانست.

جدول ۷. ماتریس درهم‌ریختگی برای طبقه‌بندی براساس روش اولزووسکی

شرایط درست		شرایط نادرست	
۹۴۸۲	۹۰۱	پیش‌بینی مثبت	
۴۲۶۷۰	۲۲۱	پیش‌بینی منفی	

جدول ۸. ماتریس درهم‌ریختگی برای طبقه‌بندی با روش پیشنهادی

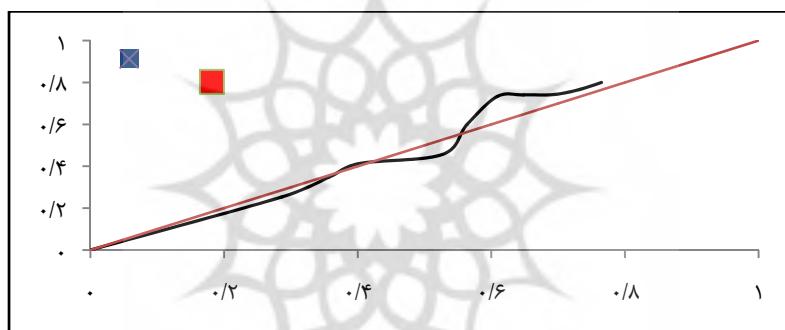
شرایط درست		شرایط نادرست	
۳۱۲۵	۱۰۲۴	پیش‌بینی مثبت	
۴۹۱۲۵	۹۸	پیش‌بینی منفی	

جدول ۹. نتیجه آزمون شبکه براساس روش‌های اولزووسکی و پیشنهادی (ارقام به درصد)

روش	حساسیت	از دست دادن	درستی	F_1	$g\text{-mean}_r$
اولزووسکی	۸۰	۱۸	۸۲	۱۶	۸۱
پیشنهادی	۹۱	۶	۹۴	۴۰	۹۲

شکل ۲ نمودار ROC هر سه رویکرد را نشان می‌دهد. سطح زیر منحنی رویکرد اول برابر ۶۹ درصد است. به علاوه، دو نقطه سمت چپ بالا، مربوط به رویکردهای تطبیقی است. در این شکل محور افقی نشان‌دهنده مشاجره و محور عمودی حساسیت است.

پس از بررسی معیارهای طبقه‌بندی، نوبت به مقایسه عملکرد الگوریتم تک‌فرایندی جدول ۱، با الگوریتم ترکیبی موازی دو سطحی جدول ۲ برای آموزش شبکه و جدول ۳ برای طبقه‌بندی تراکنش ورودی از نظر زمان اجرا می‌رسد. پارامتری که مقیاس پذیری مدل کوهوون را تحت تأثیر قرار می‌دهد، تعداد نرون‌های شبکه است. بنابراین، تعداد نرون‌ها از ۱۰ تا ۵۰ با گام‌های ۱۰ تا ۱۰ با گام‌های ۱۰ در نظر گرفته شده و زمان اجرا بررسی شد. جدول ۱۰ نتایج را نشان می‌دهد. همان‌گونه که در این جدول ملاحظه می‌شود با بالا رفتن تعداد نرون‌ها، زمان لازم برای ساخت پروفایل و طبقه‌بندی تراکنش جدید به صورت چشمگیری افزایش می‌یابد.



شکل ۲. نمودار ROC مربوط به هر سه روش اندازه‌گیری فاصله

جدول ۱۰. نتیجه آزمون الگوریتم تک‌فرایندی (اعداد براساس میلی ثانیه هستند)

تعداد نرون	زمان ساخت پروفایل					
	کمترین	متوسط	بیشترین	کمترین	متوسط	بیشترین
	زمان طبقه‌بندی تراکنش ورودی					
۱۰	۵۰	۸۰	۱۳۰	۳۰۵۹	۳۹۸	۷۳۶
۲۰	۵۳	۸۳	۱۳۰	۳۰۵۹	۴۲۰	۷۳۷
۳۰	۵۹	۹۱	۱۲۹	۳۰۴۷	۴۷۲	۹۰۷
۴۰	۶۴	۱۰۳	۱۵۷	۳۶۸۶	۵۰۹	۹۴۰
۵۰	۷۶	۱۲۰	۱۵۹	۳۷۴۷	۶۰۴	۱۰۹۶

برای دستیابی به مقیاس‌پذیری، سرعت و اجرای موازی، از الگوریتم‌های نگاشت کاهشی جدول ۲ برای ساخت پروفایل و جدول ۳ برای طبقه‌بندی استفاده شد. با مقدار M برابر ۱۵ (بیشتر تعداد فرایندهای موازی) جدول ۱۱ نتیجه آزمایش را نشان می‌دهد. همان‌طور که مشاهده می‌شود، هر دو زمان ساخت و طبقه‌بندی به‌طور شایان توجهی کاهش یافته‌اند. از سوی دیگر، افزایش تعداد نرون‌های شبکه، افزایش محسوسی را در زمان اجرا نشان نمی‌دهد.

جدول ۱۱. نتیجه آزمون الگوریتم نگاشت کاهشی موازی (اعداد براساس میلی‌ثانیه هستند)

بیشترین	زمان طبقه‌بندی تراکنش ورودی			زمان ساخت پروفایل			تعداد نرون
	کمترین	متوسط	بیشترین	کمترین	متوسط	بیشترین	
۹	۵	۶	۴۱	۱۴	۳۷	۱۰	
۱۰	۵	۶	۴۳	۱۵	۳۸	۲۰	
۱۳	۵	۸	۴۶	۱۵	۴۱	۳۰	
۱۵	۶	۹	۴۷	۱۶	۴۳	۴۰	
۱۸	۶	۱۱	۴۹	۱۷	۴۴	۵۰	

نتیجه‌گیری و پیشنهادها

پژوهش حاضر به پیشنهاد مدل مناسبی برای شناسایی تقلب تراکنش کارت‌های بانکی با رویکرد کشف ناهنجاری بدون سرپرستی با استفاده از شبکه عصبی کوهونن و نگاشت کاهش پرداخته است. با مرور پژوهش‌های صورت‌گرفته، مشخص شد که مدل پیشنهادی با در نظر گرفتن کاستی‌هایی که در مدل‌های با سرپرستی وجود دارد، نوعی روش بدون سرپرستی ارائه داده است. همچنین با توجه به الزام سرعت زیاد پردازش در محیط بزرگ‌داده، یک رویکرد نگاشت کاهشی موازی است. بنابراین، این دو خصیصه در کنار استفاده از شبکه عصبی کوهونن، نوعی نوآوری است که در ادبیات موضوع مشاهده نشد. با اجرای مدل پیشنهادی در مجموعه داده واقعی مشخص شد که رویکرد تطبیقی این مدل، در طبقه‌بندی عملکرد مناسبی را نسبت به رویکردهای کوهونن استفاده‌شده قبلی، از خود نشان داده است. در ضمن، استفاده از توان تعریف وظایف موازی و متوالی نگاشت کاهش، تأثیر شایان توجهی را هم در سرعت آموزش و هم در سرعت طبقه‌بندی دارد و در مقابل بزرگ‌شدن ابعاد (تعداد نرون‌ها)، مقیاس‌پذیر است. به‌طور خلاصه، رویکردهای تطبیقی نسبت به استفاده از مقدار برش ثابت، دقت طبقه‌بندی بیشتری دارند و در محیط بزرگ‌داده، مدل باید توان اجرای موازی مقیاس‌پذیر را داشته باشد.

نامتقارن بودن فضای جستجو، آماره F_1 را تحت تأثیر قرار داده است و تأکیدی است بر دشواری کشف ناهنجاری در داده‌های نامتقارن که در ادبیات نیز به آن اشاره شده بود. از سوی دیگر، کنکاش در تراکنش‌هایی که عدم اعلان نادرست داشتند، نشان داد که استفاده از رویکرد خوشبندی براساس رفتار تاریخی دارنده کارت، نمی‌تواند مشاهداتی که مقدار ناهنجار دارند را در مجموعه آموزش تشخیص دهد.

References

- Axelsson, S. (2000). *The Base-Rate Fallacy and the Difficulty of Intrusion Detection*. ACM Trans .Information and System Security. 3(3): 186-205.
- Bai, M., Wang, X., Xin, J. & Wang, G. (2016). *An efficient algorithm for distributed density-based outlier detection on big data*. Neurocomputing. (181): 19-28.
- Bermúdez, L., Pérez, J. M., Ayuso, M., Gómez, E. & Vázquez, F.J. (2008). *A Bayesian Dichotomous, Model with asymmetric link for fraud in insurance*. Insurance: Mathematics and Economics. 42(2): 779-786.
- Bhusari, V. & Patil, S. (2011). *Study of Hidden Markov Model in Credit Card Fraudulent Detection*. International Journal of Computer Applications. 20(5): 33-36.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Information Science and Statistics: Springer. Singapore.
- Correa Bahnsen, A., Stojanovic, A., Aouada, D. & Ottersten, B. (2016). Feature engineering strategies for credit card fraud detection. *Expert Systems With Applications*, 51: 134-142.
- Correa Bahnsen, A., Stojanovic, A., Aouada, D., Ottersten, B.(2014). *Improving credit card fraud detection with calibrated probabilities*. In Proceedings of the fourteenth siam international conference on data mining. Detroit, USA.
- Dal Pozzolo, A., Caelen, O., Le Borgne, Y. A., Waterschoot, S. & Bontempi, G. (2014). Learned lessons in credit card fraud detection from a practitioner perspective. *Expert Systems with Applications*, 41(10): 4915-4928.
- Dean, J. & Ghemawat, S. (2004). MapReduce: simplified data processing on large clusters. *OSDI'04 Proceedings of the 6th conference on Symposium on Operating Systems Design & Implementation*, 137-150.
- Duman, E. & Ozcelik, M.H. (2011). Detecting credit card fraud by genetic algorithm and scatter search. *Expert Systems with Applications*, 38(10): 13057-13063.

- Epaillard, E. & Bouguila, N. (2016). Proportional data modeling with hidden Markov models based on generalized Dirichlet and Beta-Liouville mixtures applied to anomaly detection in public areas. *Pattern Recognition*, 55: 125-136.
- González, P. C. & Velásquez, J. D. (2013). Characterization and detection of tax payers with false invoices using data mining techniques. *Expert systems with applications*, 40(5): 1427-1436.
- Halvaiee, N.S. & Akbari, M.K. (2014). A novel model for credit card fraud detection using Artificial Immune Systems. *Applied soft computing*, 24: 40-49.
- Hollmén, J., Tresp, V. & Simula, O. (1999). A self-organizing map for clustering probabilistic models. *Proceedings of the Ninth International Conference on Artificial Neural Networks*, 7-10 Sept.
- Huang, J., Zhu, Q., Yang, L. & Feng, J. (2016). A non-parameter outlier detection algorithm based on Natural Neighbor. *Knowledge-Based Systems*, 92: 71-77.
- Huang, S. Y., Tsaih, R. H. & Yu, F. (2014). Topological pattern discovery and feature extraction for fraudulent financial reporting. *Expert systems with applications*, 41(9): 4360-4372.
- Jha, S., Guillen, M. & Westland, J. C. (2012). Employing transaction aggregation strategy to detect credit card fraud. *Expert Systems with Applications*, 39(16): 12650-12657.
- Kohonen, T. (1990). The self-organizing map. In *Proceedings of the IEEE*, 78 (9): 1464-1480.
- Kotu, V., Deshpande, B. (2015). *Predictive analytics and data mining; Concepts and practice with RapidMiner*. Morgan Kaufmann. San Francisco.
- Leskovec, J., Rajaraman, A. & Ullm, J.D. (2014). *Mining of Massive Datasets*. Cambridge University Press.
- Loshin, D. (2013). *Big data analytics; from strategic planning to enterprise integration with tools, techniques, NoSQL, and graph*. Morgan Kaufmann, London.
- Minegishi, T. & Niimi, A. (2011). Proposal of Credit Card Fraudulent Use Detection by Online-type Decision Tree Construction and Verification of Generality. *International Journal for Information Security Research*, 1(4): 229-235.
- Mishra, J. S., Panda, S. & Mishra, A. K. (2013). A Novel Approach for Credit Card Fraud Detection Targeting the Indian Market. *International Journal of Computer Science Issues*, 10(3): 172-179.

- Nasiri, N. & Minayi, B. (2011). Data mining methods for credit card fraud detection. *1st International conference on E-Citizen & Cellphone*. Tehran: Frb 28-29. (in Persian)
- Ngai, E. W., Hu, Y., Wong, Y. H., Chen, Y. & Sun, X. (2011). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. *Decision Support Systems*, 50(3): 569-559.
- Olszewski, D. (2014). Fraud detection using self-organizing map visualizing the user profiles. *Knowledge-Based Systems*, 70: 324-334.
- Patidar, R. & Sharma, L. (2011). Credit Card Fraud Detection Using Neural Network. *International Journal of Soft Computing and Engineering*, (1): 32-37.
- Phua, C., Lee, V., Smith, K. & Gayler, R. (2005). A Comprehensive Survey of Data Mining-based Fraud Detection Research. *Artificial Intelligence Review*, 1-14.
- Powers, D. M.W. (2011). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness, correlation. *Journal of Machine Learning Technologies*, 2 (1): 37-63.
- Qibei, L. & Chunhua, J. (2011). Research on Credit Card Fraud Detection Model Based on Class Weighted Support Vector Machine. *Journal of Convergence Information Technology*, 6(1): 62-68.
- Quah, J. T.S. & Sriganesh, M. (2008). Real-time credit card fraud detection using computational intelligence. *Expert Systems with Applications*, 35(4): 1721-1732.
- Raj, B. E. & Portia, A. (2011). Analysis on Credit Card Fraud Detection Methods. *International Conference on Computer, Communication and Electrical Technology*, March.
- Rama Kalyani, K. & Uma Devi, D. (2012). Fraud Detection of Credit Card Payment System by Genetic Algorithm. *International Journal of Scientific & Engineering Research*, 3(7): 1-6.
- Rojas, R. (1996). *Neural Networks*. Berlin: Springer-Verlag.
- Srivastava, A., Kundu, A., Sural, S. & Majumdar, A. K. (2008). Credit Card Fraud Detection Using Hidden Markov Model. *IEEE transactions on dependable and secure computing*, 5(1): 37-48.
- Swets, J.A. (1996). *Signal Detection Theory and ROC Analysis in Psychology and Diagnostics: Collected Papers*. Lawrence Erlbaum Associates, Mahwah, N.J.

- Tripathi, K.K. & Ragha, L. (2013). Hybrid Approach for Credit Card Fraud Detection. *International Journal of Soft Computing and Engineering*, 3(4): 8-11.
- Vosough, M., Taghavifard, M.T. & Alborzi, M. (2015). Bank card fraud detection using artificial neural network. *Journal of Information Technology Management*, 6(4): 721-746. (in Persian)
- Whitrow, C., Hand, D.J., Juszczak, P. & Weston, D. (2008). Transaction aggregation as a strategy for credit card fraud detection. *Data mining and knowledge discovery*, 18(1): 30-55.
- Zareapoor, M., Seeja, K.R. & Alam, M. A.(2012). Analysis of credit card fraud detection techniques: based in certain design criteria. *International journal of computer applications*, 52(3): 35-42.
- Zareapoor, M. & Shamsolmoali, P. (2015). Application of credit card fraud detection: based on bagging ensemble classifier. *Procedia computer science*, 48: 679-685.
- Zaslavsky, V. & Strizhak, A. (2006). Credit card fraud detection using self organizing maps. *International Journal of Information & Security*, 18: 48-63.



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرستال جامع علوم انسانی